


UNIVERSIDADE FEDERAL DO PARANÁ

NATÁLIA SABARIEGO

MODELAGEM DE TELHADOS A PARTIR DE NUVEM DE PONTOS LIDAR  
UTILIZANDO ALGORITMOS GENÉTICOS

CURITIBA

2018



NATÁLIA SABARIEGO

MODELAGEM DE TELHADOS A PARTIR DE NUVEM DE PONTOS LIDAR  
UTILIZANDO ALGORITMOS GENÉTICOS

Dissertação apresentada ao curso de Pós-Graduação em Ciências Geodésicas, Setor de Ciências da Terra, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Mestre em Ciências Geodésicas.

Orientador: Prof. Dr. Jorge Antonio Silva Centeno

CURITIBA

2018

Catálogo na Fonte: Sistema de Bibliotecas, UFPR  
Biblioteca de Ciência e Tecnologia

---

S113m Sabariego, Natália  
Modelagem de telhados a partir de nuvem de pontos LIDAR  
utilizando algoritmos genéticos [recurso eletrônico] / Natália  
Sabariego – Curitiba, 2018.

Dissertação - Universidade Federal do Paraná, Setor de  
Ciências da Terra, Programa de Pós-graduação em Ciências  
Geodésicas.


Orientador: Jorge Antonio Silva Centeno

1. Algoritmos genéticos. 2. Geodésia. 3. Feixes de laser. 3.  
Telhado. I. Universidade Federal do Paraná. II. Centeno, Jorge  
Antonio Silva. IV. Título.

CDD: 526.640285

---

Bibliotecária: Roseny Rivelini Morciani CRB-9/1585



MINISTÉRIO DA EDUCAÇÃO  
SETOR SETOR DE CIÊNCIAS DA TERRA  
UNIVERSIDADE FEDERAL DO PARANÁ  
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO CIÊNCIAS  
GEODÉSICAS

## TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em CIÊNCIAS GEODÉSICAS da Universidade Federal do Paraná foram convocados para realizar a arguição da dissertação de Mestrado de **NATALIA SABARIEGO** intitulada: **MODELAGEM DE TELHADOS A PARTIR DE NUVEM DE PONTOS LIDAR UTILIZANDO ALGORITMOS GENÉTICOS**, após terem inquirido a aluna e realizado a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 31 de Outubro de 2018.

JORGE ANTONIO SILVA CENTENO  
Presidente da Banca Examinadora (UFPR)

HENRIQUE FIRKOWSKI  
Avaliador Externo (UFPR)

HIDEO ARAKI  
Avaliador Interno (UFPR)

ALZIR FELIPPE BUFFARA ANTUNES  
Avaliador Interno (UFPR)

Dedico este trabalho aos meus pais José e Luciana, que são minha base, meu porto seguro, minha fonte de amor. Ao meu companheiro Niarkios que desde o início foi minha grande motivação. E ao meu orientador Jorge Centeno que acreditou em mim, me incentivou e me fez crescer profissional e pessoalmente.

## **AGRADECIMENTOS**

Agradeço primeiramente ao meu orientador Dr. Jorge Antonio Silva Centeno pela orientação e pelos ensinamentos. Agradeço imensamente pela confiança, paciência e dedicação no desenvolvimento deste projeto de pesquisa.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq, pela oportunidade da bolsa de Mestrado.

À secretária do CPGCG, Mônica Kleuser, por sua dedicação e apoio ao longo dessa jornada.

Aos colegas Livia F. Sampaio, Ilich Contreras, Felipe Costa, Mario E. J. Palma e Caisse Amisse, pelos ensinamentos, apoio e amizade.

À minha família por me apoiar, acreditar em mim e principalmente pela compreensão.

Ao meu companheiro Niarkios L.S.S.Graça pela paciência, força, parceria, compreensão, apoio, ensinamentos, carinho e por estar ao meu lado durante todo o processo.

E finalmente aos meus pais José Sabariego Ruiz Filho e Luciana Sabariego pelo apoio, a motivação, a confiança, a paciência, a compreensão e principalmente pelo amor incondicional. Sem eles eu não seria nada. Obrigada.

Na maioria das vezes, a diferença entre vencer e perder consiste em não desistir. (WALT DISNEY).



## RESUMO

Esta pesquisa aborda a modelagem de telhados a partir de nuvens de pontos, utilizando algoritmos genéticos. Para isso, primeiramente, foi desenvolvido um algoritmo para detecção de bordas. Foram realizados experimentos com nuvens de pontos simuladas e nuvens de pontos reais, obtidas por LIDAR. Nos experimentos com nuvens de pontos simuladas, foram criados três tipos de nuvens de pontos com diferentes complexidades, e foram avaliados os efeitos do ruído e da densidade de pontos nos resultados. Para os experimentos com nuvens de pontos reais, o pré-processamento foi realizado no software Lastools, isolando os pontos referentes a telhados determinados. Nesse caso, foram escolhidos cinco telhados para a apresentação dos resultados, tendo cada um deles uma característica diferente. A utilização dos algoritmos genéticos mostrou-se eficiente para a modelagem de telhados. O algoritmo permitiu que os pontos significativos, as arestas, fossem encontrados dentro do limite esperado. E a modelagem final de todos os experimentos apresentou resultado satisfatório.

Palavras-chave: Modelagem. Telhados. Algoritmos genéticos. Nuvem de pontos. LIDAR.



## **ABSTRACT**

This research approaches the modeling of roofs from point clouds using genetic algorithms. For this, first of all, an algorithm for edge detection was developed. Experiments were performed with simulated point clouds and real point clouds, obtained by LIDAR. In the experiments with simulated point clouds, three types of point clouds with different complexities were created, and the effects of noise and point density on the results were evaluated. For the experiments with clouds of real points, the pre-processing was performed on Lastools software, isolating the points referring to certain roofs. In this case, five roofs were chosen for the presentation of the results, each having a different characteristic. The use of genetic algorithms proved to be efficient for the modeling of roofs. The algorithm allowed the significant points, the edges, to be found within the expected limit. And the final modeling of all the experiments presented satisfactory results.

Keywords: Modeling. Roofs. Genetic algorithms. Point clouds. Light Detection And Ranging - *LIDAR*.

## LISTA DE FIGURAS

FIGURA 1 – REPRESENTAÇÃO GRÁFICA DO RETÂNGULO IDEAL E OS PONTOS QUE MELHOR REPRESENTAM SUA MODELAGEM. ....	31
FIGURA 2 – FLUXOGRAMA DO ALGORITMO QUE REGE O PROCESSO ITERATIVO. ....	34
FIGURA 3 – EXEMPLO DA ROLETA PARA O CASO DA TABELA 3. ....	38
FIGURA 4 – ALGORITMO BÁSICO DO MÉTODO DE SELEÇÃO POR ROLETA. ...	38
FIGURA 5 – ALGORITMO BÁSICO DO MÉTODO DE SELEÇÃO POR TORNEIO. ...	39
FIGURA 6 – CRUZAMENTO EM UM PONTO. ....	41
FIGURA 7 – CRUZAMENTO EM DOIS PONTO. ....	42
FIGURA 8 – CRUZAMENTO UNIFORME. ....	42
FIGURA 9 – ALGORITMO DE UMA MÁSCARA DE CRUZAMENTO. ....	43
FIGURA 10 - ILUSTRAÇÃO DA MUTAÇÃO SIMPLES. ....	43
FIGURA 11 - EXEMPLO DE MODELAGEM DE TELHADO: (A) NUVEM DE PONTOS DE UM TELHADO (AZUL) E OS PONTOS MAIS SIGNIFICANTES (VERMELHO); (B) MODELO OBTIDO A PARTIR DOS PONTOS SIGNIFICANTES. ....	47
FIGURA 12 - EXEMPLO DE UMA TRIANGULAÇÃO DE DELAUNAY. ....	48
FIGURA 13 - REPRESENTAÇÃO DO TELHADO USANDO UMA TRIANGULAÇÃO: (A) EM 3D; (B) EM PLANTA. ....	49
FIGURA 14 - PROCESSO ITERATIVO DE APROXIMAÇÃO DE TELHADOS. ....	55
FIGURA 15 - REPRESENTAÇÃO DE DOIS VETORES NUM PLANO. ....	56
FIGURA 16 - REPRESENTAÇÃO DO PRODUTO VETORIAL ENTRE DOIS VETORES. ....	57
FIGURA 17 - REPRESENTAÇÃO DO VETOR NORMAL COM VETOR $P_0P_1$ . ....	57
FIGURA 18 - REPRESENTAÇÃO DO TELHADO 1 (DUAS ÁGUAS). ....	63
FIGURA 19 - REPRESENTAÇÃO DO TELHADO 2 (QUATRO ÁGUAS). ....	63
FIGURA 20 - REPRESENTAÇÃO DO TELHADO 3 (OITO ÁGUAS). ....	63
FIGURA 21 - EXEMPLO DO PROCESSO DE REDUÇÃO DA DENSIDADE DE PONTOS. ....	64
FIGURA 22 - EVOLUÇÃO DAS ITERAÇÕES PARA A MODELAGEM DO TELHADO 1, COM ESPAÇAMENTO DE 5M E NÍVEL DE RUÍDO DE 5CM. ....	66
FIGURA 23 - MODELAGEM FINAL DO TESTE A. ....	66

FIGURA 24 - MODELAGEM FINAL DOS TESTES B A E.....	68
FIGURA 25 - EVOLUÇÃO DAS ITERAÇÕES PARA A MODELAGEM DO TELHADO 2, COM ESPAÇAMENTO DE 3M E NÍVEL DE RUÍDO DE 5CM.....	70
FIGURA 26 - MODELAGEM FINAL DO TELHADO 2 CONSIDERANDO DIFERENTES ESPAÇAMENTOS ENTRE LINHAS: 3m E 5m. ....	70
FIGURA 27 - EVOLUÇÃO DAS ITERAÇÕES PARA A MODELAGEM DO TELHADO 3, COM ESPAÇAMENTO ENTRE LINHAS DE 3m E RUÍDO DE 5cm. .....	72
FIGURA 28 - EVOLUÇÃO DA MODELAGEM DE ACORDO COM AS ITERAÇÕES REFERENTES AO TELHADO 3 (ESPAÇAMENTO ENTRE LINHAS DE 3m E RUÍDO 5cm). ....	72
FIGURA 29 – MODELAGEM FINAL DO TELHADO 3 COM ESPAÇAMENTOS ENTRE LINHAS DE 3m E 5m.....	73
FIGURA 30 - PRIMEIRA ÁREA REFERENTE À CIDADE DE RECIFE PARA A REALIZAÇÃO DOS EXPERIMENTOS. ....	74
FIGURA 31 - SEGUNDA ÁREA REFERENTE À CIDADE DE RECIFE PARA A REALIZAÇÃO DOS EXPERIMENTOS. ....	75
FIGURA 32 - NUVEM DE PONTOS ORIGINAL DO TELHADO CASA 1.....	76
FIGURA 33 - EVOLUÇÃO DO CONJUNTO DE ITERAÇÕES PARA A MODELAGEM DO TELHADO CASA 1.....	76
FIGURA 34 - EVOLUÇÃO DA MODELAGEM DE ACORDO COM AS ITERAÇÕES REFERENTES AO TELHADO CASA 1. ....	78
FIGURA 35 - MODELAGEM FINAL DO TELHADO CASA 1 E SEU RESULTADO APÓS A REMOÇÃO DE ARESTAS COM ÂNGULOS MENORES DE QUE 45 GRAUS.....	78
FIGURA 36 - NUVENS DE PONTOS ORIGINAIS DOS TELHADOS (A) CASA 2, (B) CASA 3, (C) CASA 4 E (D) CASA 5.....	79
FIGURA 37 - EVOLUÇÃO DO CONJUNTO DE ITERAÇÕES PARA A MODELAGEM DOS TELHADOS: (A) CASA 2, (B) CASA 3, (C) CASA 4 E (D) CASA 5. ....	80
FIGURA 38 - MODELAGEM FINAL DOS TELHADOS (A) CASA 2, (B) CASA 3, (C) CASA 4 E (D) CASA 5. ....	81

FIGURA 39 - PONTOS DE BORDAS (VERMELHO) E INTERNOS (AZUL) SUPERPOSTOS A TRIANGULAÇÃO DO PRIMEIRO RESULTADO PARCIAL.....	83
---	----

## LISTA DE TABELAS

TABELA 1 – PRINCIPAIS ABORDAGENS PARA A SOLUÇÃO DO PROBLEMA DE MODELAGEM DE TELHADOS.....	22
TABELA 2 – EXEMPLOS DE GENÓTIPOS E FENÓTIPOS CORRESPONDENTES A UM PROBLEMA SIMPLES: DETERMINAR QUAL É O MENOR NÚMERO DE PONTOS QUE MELHOR DESCREVE OS CONTORNOS DE UM RETÂNGULO. ....	32
TABELA 3 – GRUPO ALEATÓRIO DE INDIVÍDUOS, SEUS RESPECTIVOS <i>FITNESS</i> E PARCELA NA ROLETA.....	38
TABELA 4 – PARÂMETROS GENÉTICOS.....	62
TABELA 5 - VALORES DOS RUÍDOS DETERMINADOS PARA CADA EXPERIMENTO. ....	65
TABELA 6 - COMPARAÇÃO ENTRE OS PONTOS SIGNIFICATIVOS OBTIDO PELO ALGORITMO E OS ORIGINAIS. ....	67
TABELA 7 - RESULTADOS NUMÉRICOS OBTIDOS DOS TESTES DE A A E.....	67
TABELA 8 - RESUMO DA ANÁLISE DO ERRO VARIANDO A DISTÂNCIA ENTRE LINHAS REFERENTE AOS EXPERIMENTOS COM O TELHADO 2. ....	70
TABELA 9 - RESUMO DA ANÁLISE DO ERRO VARIANDO A DISTÂNCIA ENTRE LINHAS REFERENTE AOS EXPERIMENTOS COM O TELHADO 3. .....	72
TABELA 10 - RESUMO DA ANÁLISE DO ERRO VARIANDO NOS EXPERIMENTOS COM O TELHADO CASA 1 A 4 . ....	84

## SUMÁRIO

<b>1 INTRODUÇÃO .....</b>	<b>16</b>
1.1 JUSTIFICATIVA .....	17
1.2 OBJETIVOS .....	18
1.2.1 Objetivo geral .....	18
1.2.2 Objetivos específicos.....	18
<b>2 REVISÃO DE LITERATURA .....</b>	<b>19</b>
2.1 LIDAR.....	19
2.2 TRABALHOS RELACIONADOS .....	21
2.2.1 LIDAR com integração de dado auxiliar .....	22
2.2.1.1 LIDAR e dados cartográficos digitais.....	22
2.2.1.2 LIDAR e imagens.....	23
2.2.2 LIDAR sem integração de dado auxiliar .....	24
2.2.2.1 Dicionário de formas de telhados .....	24
2.2.2.2 Detecção de planos .....	25
2.2.2.3 Crescimento de regiões em uma grade raster.....	26
2.2.2.4 Crescimento de regiões em uma estrutura TIN ( <i>Triangulated Irregular Network</i> ).....	26
2.2.3 Análise de arestas .....	27
2.2.4 Outros métodos .....	27
2.2.5 Contextualização da pesquisa.....	28
2.3 ALGORITMOS GENÉTICOS .....	29
2.3.1 Indivíduos .....	30
2.3.2 Populações.....	32
2.3.3 Funcionamento dos AGs .....	33
2.3.3.1 Inicialização .....	35
2.3.3.2 Função de Adequação.....	36
2.3.3.3 Seleção.....	37
2.3.3.4 Operadores genéticos .....	40
2.3.3.5 Atualização .....	44
2.3.3.6 Finalização .....	45
<b>3 MATERIAL E MÉTODOS .....</b>	<b>46</b>

3.1 DEFINIÇÃO DO PROBLEMA.....	46
3.1.1 Triangulação de Delaunay.....	48
3.1.2 Detecção de bordas .....	49
3.2 PROPOSTA DOS ALGORITMOS GENÉTICOS.....	52
3.3 PROPOSTA DA FUNÇÃO DE ADEQUAÇÃO.....	53
3.4 O ALGORITMO .....	58
3.4.1 Detecção de pontos significativos .....	59
3.4.2 Redução progressiva da densidade .....	60
3.4.3 Algoritmos genéticos .....	60
3.5 AVALIAÇÃO .....	61
<b>4 APRESENTAÇÃO DOS RESULTADOS .....</b>	<b>62</b>
4.1 NUENS DE PONTOS SIMULADAS.....	62
4.1.1 Experimento I: efeito do ruído .....	65
4.1.2 Experimento II: efeito da densidade de pontos .....	69
4.2 NUENS DE PONTOS REAIS (LIDAR).....	74
4.2.1 Área de estudo .....	74
4.2.2 Telhado Casa 1 .....	75
4.2.3 Telhado Casa 2/ Casa 3/ Casa 4/ Casa 5 .....	79
<b>5 CONSIDERAÇÕES FINAIS .....</b>	<b>85</b>
5.1 RECOMENDAÇÕES PARA TRABALHOS FUTUROS .....	88
<b>REFERÊNCIAS.....</b>	<b>89</b>



## 1 INTRODUÇÃO

As pesquisas voltadas para a área de extração de feições vêm crescendo nos últimos anos. Em particular, a extração de telhados de edifícios vem sendo estudada por mais de três décadas (MARCATO e DAL POZ, 2014). Sua modelagem tridimensional permite aplicações em atualização, cadastro, locação de antenas de rádio e telefonia, planejamento de áreas urbanas, estudos relacionados à energia solar, entre outras.

De acordo com Yano, Dal Poz e Mendes (2013), até meados da década de 90, os dados disponíveis para a extração e reconstrução de edificações eram imagens aéreas de alta resolução. No entanto, no final dessa mesma década, novas fontes de dados passaram a serem utilizadas, destacando-se os dados LIDAR (Light Detection and Ranging). O desenvolvimento de metodologias que utilizam esse tipo de dados para mapeamento é bastante atrativo às aplicações que envolvem a reconstrução e extração de objetos, procurando a solução de problemas específicos (MARCATO e DAL POZ, 2014).

Essa nova fonte de dados se revelou mais eficaz em alguns aspectos, se comparada às imagens aéreas. Quando se trata da obtenção de planos de telhados e sua orientação, as nuvens de pontos obtidas com os dados LIDAR apresentam melhores resultados, uma vez que é disponibilizada uma grande quantidade de pontos na superfície do objeto, enquanto que em imagens os planos de telhados são homogêneos, o que dificulta a obtenção de informação posicional densa ao longo deles com o uso de técnicas fotogramétricas (YANO, DAL POZ e MENDES, 2013).

Segundo Yano, Dal Poz e Mendes (2013) os princípios mais utilizados para a extração e modelagem de edifícios a partir de dados LIDAR podem ser divididos em três abordagens: aplicação de métodos de detecção de bordas de telhados; agrupamento de pontos coplanares para detecção de planos de telhados, como em Ercolin Filho, Centeno e Mitishita (2016); e intersecção de planos de telhados para a extração de cumeeiras, como em Botelho e Centeno (2007). Estas abordagens se baseiam na estimativa dos planos que compõem o telhado para assim modelar as interseções que definem sua forma. Um problema comum é a necessidade de estimar, a princípio, quantos planos formam o telhado, para assim selecionar pontos representativos de cada plano que sirvam para a estimativa de uma equação que o descreva.

Neste projeto de pesquisa foi desenvolvida e apresentada uma abordagem diferente. Nesta abordagem buscou-se, numa nuvem de pontos referente a um determinado telhado, os pontos significativos (arestas do telhado) sem necessidade de inicialmente propor a quantidade de planos a serem modelados. Portanto, foi proposto o uso de algoritmos genéticos (AGs) como ferramenta de busca da solução ótima para este problema.

Os AGs são conjuntos de procedimentos lógicos que tem por finalidade simular os processos de evolução biológica, compreendendo o fenômeno da adaptação que ocorre na natureza e transformando-o viável e concreto no universo computacional. Seu objetivo consiste, de maneira geral, em resolver problemas, modelar sistemas evolutivos e ser uma ferramenta de otimização nas mais variadas áreas. Estes algoritmos fazem parte da chamada “computação evolutiva” (CE), uma alternativa que visa resolver problemas complexos.

## 1.1 JUSTIFICATIVA

Com a evolução da tecnologia, a extração de feições, mesmo com diversas finalidades, vem se tornando cada vez mais importante e popular. Quando se trata da extração de telhados de edificações e sua modelagem tridimensional, pode-se notar que suas aplicações em cadastro, locação de antenas de rádio e telefonia, planejamento de áreas urbanas, estudos relacionados à energia solar, entre outras, se tornam cada vez mais importantes. Essas aplicações interferem diretamente em impostos a serem pagos, regularização de imóveis, controle financeiro de empresas de telefonia e energia, desenvolvimento nas áreas de novas fontes de energia, assim como no planejamento urbano, que vem crescendo, se desenvolvendo e tem sua importância cada vez mais evidente.

Neste projeto de pesquisa, com o objetivo de otimizar o processo de modelagem de telhados, foi proposta uma abordagem diferente. Pretendeu-se identificar, numa nuvem de pontos referente a um determinado telhado, os pontos significativos desse telhado, suas arestas, sem a necessidade, a princípio, de propor a quantidade de planos a serem modelados. Os algoritmos genéticos são técnicas estocásticas de otimização, inspiradas na evolução de sistemas biológicos, usando as metáforas de mecanismos de seleção natural, recombinação genética e sobrevivência dos indivíduos mais aptos (SANTOS, 2008). Assim, os algoritmos genéticos (AGs)

surgiram como uma proposta de ferramenta de busca da solução ótima para esse problema.

## 1.2 OBJETIVOS

A seguir são apresentados o objetivo geral e os objetivos específicos deste trabalho.

### 1.2.1 Objetivo geral

No presente trabalho tem-se como objetivo modelar telhados de faces planas, a partir de nuvens de pontos obtidas com LIDAR, utilizando algoritmos genéticos.

### 1.2.2 Objetivos específicos

Como objetivos específicos tem-se:

- i. Desenvolver um método de detecção de bordas e quinas para nuvens de pontos de telhados;
- ii. Propor uma função de adequação para o problema de modelagem da forma de telhados com AGs.
- iii. Avaliar o efeito do ruído nos dados em busca da solução ótima.
- iv. Avaliar o efeito da densidade de pontos na busca da solução ótima.
- v. Avaliar o método com dados simulados e dados reais.

## 2 REVISÃO DE LITERATURA

A seguir é apresentada a revisão de literatura para o presente trabalho de pesquisa. Inicialmente foi descrita a aquisição de dados LIDAR, seguida de uma revisão de trabalhos, encontrados na literatura, a respeito da modelagem de telhados usando dados LIDAR, e por fim foram descritos os princípios dos AGs.

### 2.1 LIDAR

LIDAR (Light Detection and Ranging) é a tecnologia que se utiliza da luz na forma de um laser, para fazer a varredura de uma superfície, medindo as distâncias entre a fonte LASER e a superfície. O tratamento deste feixe de distâncias em um referencial apropriado permite gerar dados tridimensionais sem que haja contato direto com o(s) objeto(s). Esta tecnologia atende a necessidade crescente de dados tridimensionais da superfície dos objetos.

Como Wehr e Lohr (1999) descrevem, a tecnologia se baseia na emissão de um pulso LASER e o registro de sua reflexão após o contato com a superfície. A principal função do sistema LIDAR consiste em estimar a distância entre o sensor e a superfície. Para determinar a posição do local onde o raio atingiu a superfície são necessários dados auxiliares, como a posição e a orientação do emissor/receptor. Estes sistemas permitem a coleta de dados tridimensionais, tanto de objetos a curta distância (LIDAR terrestre) quanto a longas distâncias (LIDAR aerotransportado), a partir de plataformas aéreas (aeronaves ou helicópteros), a fim de medir a topografia do terreno e outros elementos presentes acima da superfície da Terra.

A distância  $R$  entre o sensor e a superfície do objeto é estimada com base no intervalo de tempo no qual o pulso emitido percorre o espaço até a superfície e volta para o sensor, conforme a equação 1:

$$R = \frac{c \cdot \Delta T}{2} \quad (1)$$

Em que:

$R$  – distância entre o sensor e a superfície do objeto;

$\Delta T$  – o tempo entre emissão e captação;

$c$  – a velocidade de propagação da energia eletromagnética (velocidade da luz).

O sistema LIDAR aerotransportado é composto por três componentes principais: o varredor LASER, propriamente dito; um receptor GNSS (Global Navigation Satellite System); e uma Unidade de Medição Inercial (UMI). O varredor LASER emite pulsos de laser e possui um sistema de varredura ótico-mecânico que direciona cada pulso emitido na direção perpendicular à trajetória da aeronave com ângulos conhecidos. A parcela refletida pela superfície do objeto iluminado pelo LASER é também medida por este dispositivo, que funciona como emissor/receptor do pulso LASER. A diferença de tempo entre a emissão e o registro do retorno é a base para o cálculo da distância entre o sensor e o objeto iluminado. O receptor GNSS é instalado na aeronave, integrado à UMI, para medir a posição e a orientação do sistema ao longo do tempo. Combinando estes três sistemas, é possível obter coordenadas tridimensionais dos pontos na superfície da Terra. Tanto a precisão quanto a acurácia dos dados estão relacionadas com os componentes do sistema e sua calibração (DALMOLIN e SANTOS, 2003). A vantagem desse sistema de varredura é o fato ser possível medir uma grande quantidade de pontos por segundo, o que produz um levantamento denso de pontos na superfície dos objetos. Desta forma tem-se um alto grau de detalhe, decorrente da alta densidade de pontos medidos, facilitando tanto a identificação de objetos e da topografia, como o mapeamento de uma porção do terreno (KERSTING et. al, 2005). O conjunto de pontos coletados, devido à sua alta densidade, é denominado “nuvem de pontos”, termo hoje consagrado na literatura.

A equação geral do sistema LIDAR é descrita na equação 2.

$$X_G = X_0 + M_{altitude} * P + M_{altitude} * M_{alinhamento} * M_{emissão} * R \quad (2)$$

Em que,

$X_G$ : coordenadas do ponto no terreno;

$X_0$ : posição dada pelo GNSS/GPS;

$M_{altitude}$ : matriz que representa a altitude da plataforma;

$P$ : distância entre o receptor GNSS/GPS e o varredor laser;

$M_{alinhamento}$ : matriz de rotação relativa entre a UMI e o varredor LASER;

$M_{emissão}$ : ângulo de varredura do LASER;

$R$ : distância, conforme a equação 1 (pág. 19). Podendo ser escalar ou também um vetor com único elemento ( $R \ 0 \ 0$ ), como se pode observar em Habib, Kersting e Bang et al. (2009).

Como Yano (2015) aponta, o uso da tecnologia LIDAR aerotransportado permite coletar alta densidade de pontos 3D com precisão e acurácia equivalentes às técnicas tradicionais de levantamento *in situ* e Fotogrametria, e com o detalhe de ser em um curto intervalo de tempo. Desta forma, os dados de LIDAR permitem uma variedade de aplicações como: reconstrução de superfícies; extração de feições; modelagens urbanas; entre outros.

## 2.2 TRABALHOS RELACIONADOS

Quando se trata de extração da classe edifícios, algumas pesquisas podem ser destacadas, como: Sohn e Dowman (2002), que utilizaram dados LIDAR para gerar dados de altura/altitude para objetos numa região urbana, assim os objetos que tinham uma certa altura acima do nível do solo, foram identificados. Em seguida, usando o índice NDVI (Normalized Difference Vegetation Index) e outras informações, distinguiram os edifícios de outros objetos. Já Dash et al. (2004), utilizaram variação de altura/altitude para desenvolver um método baseado no desvio padrão ordenado, a fim de distinguir entre árvores e edificações.

No que se refere à modelagem da forma de telhados, na literatura científica são abordadas diferentes estratégias relacionadas à detecção, extração e modelagem de telhados utilizando dados LIDAR. Alguns desses trabalhos serão citados posteriormente. Em alguns deles, pode-se observar a integração desses dados com outros tipos dados e métodos, como: imagens ópticas; Modelos digitais de Superfície normalizados e Modelos digitais de Elevação; vetorização; pontos e planos; cadeia de Markov; algoritmos genéticos; entre outros.

A seguir, na Tabela 1, são apresentadas as principais abordagens para a solução deste problema com alguns exemplos representativos:

TABELA 1 – PRINCIPAIS ABORDAGENS PARA A SOLUÇÃO DO PROBLEMA DE MODELAGEM DE TELHADOS.

<b>Integração de Dados</b>	<b>Dados</b>		<b>Exemplo</b>
Sim	LIDAR e dados cartográficos	Usando plantas dos edifícios	Vosselman e Dijkman (2001); Park et al. (2006); Haala et al. (1998); Miliaresis e Kokkas (2007).
Sim	LIDAR e fotografias aéreas	Usando LIDAR e fotografias aéreas/imagem multiespectral	Rottensteiner et al. (2004). Awrangjeb et al. (2012)
Não	LIDAR	Usando um dicionário de formas de telhados	Orthubera e Avbelj (2015); Lafarge et al. (2010); Rychard e Borkowski (2016).
Não	LIDAR em raster	Por crescimento de regiões em uma grade raster	Jochem et al. (2012).
Não	LIDAR	Por crescimento de regiões em uma estrutura TIN	Sampath e Shan (2010).
Não	LIDAR	Detecção de planos	Rottensteiner e Briesse (2003).
Não	LIDAR	Análise de arestas	Kim e Shan (2011).
Não	LIDAR e Algoritmos genéticos	Otimização da altura e inclinações da empena de telhados	Kabolizade et al. (2012).

FONTE: A autora (2018).

### 2.2.1 LIDAR com integração de dado auxiliar

Neste grupo são incluídas as abordagens em que se utilizam informações derivadas de mapas ou de imagens de satélite.

#### 2.2.1.1 LIDAR e dados cartográficos digitais

Mapas de grande escala podem ser usados para colaborar na detecção e modelagem de telhados. Os mapas são usados para separar os edifícios na nuvem de pontos, evitando o trabalho de detecção de prédios. Na modelagem, os contornos da edificação são usados para assistir a modelagem do telhado. Um exemplo desta



abordagem pode também ser encontrado em Vosselman e Dijkman (2001). A vantagem do método é que as bordas do telhado podem ser bem definidas, de forma mais eficiente quando comparadas com a utilização dos dados LIDAR apenas.

Park, Lee e Choi (2006) propuseram o desenvolvimento de um método com uma abordagem automática para a extração de edificações a partir de dados laser e mapa digital. Essa extração, que consiste em na extração de primitivas e a modelagem, é baseada principalmente numa segmentação robusta de regiões planas a partir de dados LASER. As primitivas primárias foram usadas como referências para gerar primitivas secundárias, como bordas e cantos, e depois refinadas com base nestas primitivas secundárias para formar um modelo poliédrico completo.

Já, Miliaresis e Kakkos (2007), propuseram um método para extrair uma classe de edificações utilizando MDEs e dados LIDAR com base nos princípios de segmentação geomorfométrica.

#### 2.2.1.2 LIDAR e imagens

Restringir a análise a apenas dados geométricos, pode produzir resultados limitados, o que justifica as pesquisas que enfatizam a integração de dados LIDAR com imagens, sejam fotografias aéreas ou imagens de satélite. Isto, claro, quando se dispõe destas imagens.

Awrangjeb, Zhang e Fraser (2012), propuseram um método para reconstrução automática de telhados 3D através da integração de dados LIDAR com uma imagem multiespectral. As imagens multiespectrais são usadas em duas etapas. Primeiro são usadas para separar os telhados de outros objetos elevados que podem estar superpostos ou adjacentes ao mesmo, como árvores. Em seguida, as imagens também são incluídas no processo de detecção de retas que descrevem o telhado. Os pontos, da nuvem de pontos, próximos a segmentos de retas longos de contornos de telhados são utilizados para gerar planos de telhados, assim como selecionar as demais retas que compõem o telhado de cada edificação.

Já Marcato e Dal Poz (2014) propuseram um método para refinar geometricamente telhados 3D a partir de dados LIDAR, imagens aéreas de alta-resolução e modelos de campo aleatório de Markov (MRF – *MarkovRandom Field*). Foi desenvolvida uma descrição MRF para o agrupamento de retas assumindo que os lados de contornos e cumeeiras projetados são topologicamente corretos e,

portanto, é necessário apenas melhorar a acurácia. O modelo MRF foi formulado com base em injunções geométricas, de proximidade e de orientação entre as retas extraídas da imagem e o polígono projetado. A partir daí algoritmos genéticos foram utilizados para minimizar a função de energia associada à descrição MRF, resultando em um agrupamento de retas para cada telhado, tendo o agrupamento de retas reconstruído topologicamente com base no polígono correspondente projetado no espaço imagem.

Outros exemplos de integração de dados LIDAR e dados espectrais são encontrados em Machado e Mitishita (2006), Cheng et al. (2008), Dal Poz et al. (2009), Yong Li et al. (2013), Potje et al. (2014), Marcato (2016) e Oliveira (2016). Estes métodos fazem pleno uso das vantagens complementares dos dados LIDAR e imagens ópticas.

Por fim, em Marcato (2016), o processo de identificação de contornos de telhados é realizado por meio da otimização de uma função de energia estabelecida com base em MRF, que modela propriedades de contornos de telhados e são utilizados tanto os polígonos extraídos da imagem quanto os polígonos dos dados LIDAR. A função de energia foi otimizada por um algoritmo genético.

### 2.2.2 LIDAR sem integração de dado auxiliar

Neste grupo incluem-se as abordagens que não dependem de outra fonte de informações, apenas da nuvem de pontos LIDAR. Os métodos baseados nos dados propriamente ditos consistem em segmentar a nuvem de pontos de maneira a detectar partes dos elementos do telhado. Em seguida, estes elementos são combinados para reconstruir o telhado completo. A vantagem deste tipo de abordagem é que não é restrito a formas pré-definidas, porém demanda alto esforço computacional.

#### 2.2.2.1 Dicionário de formas de telhados

Como apontam Orthubera e Avbelj (2015), modelar a forma dos telhados requer identificar pontos individuais significativos dos edifícios de uma cena de LIDAR. Em sua pesquisa, foi construído, inicialmente, um dicionário de possíveis formas dos telhados (duas águas, um plano inclinado, superfície horizontal, etc). O processo

consiste em verificar se a nuvem de pontos do telhado pode ser aproximada por uma destas formas.

Um exemplo mais recente é descrito em Rychard e Borkowski (2016), que desenvolveram um método automatizado que permite o reconhecimento e a interpretação semântica das estruturas de construção topológica. Estes autores propuseram uma decomposição inequívoca de objetos complexos em estruturas paramétricas simples predefinidas, o que resulta na reconstrução de uma unidade topológica sem elementos de sobreposição independentes. A metodologia apresentada combinou informações baseadas em dados refletidos em um gráfico de topologia de telhado atribuído a conhecimentos comuns sobre edifícios armazenados em uma biblioteca de estruturas elementares. O algoritmo de modelagem proposto tem início na extração do plano do telhado, realizada pela segmentação das nuvens de pontos, seguido da identificação de topologia e reconhecimento de estruturas predefinidas.

Lafarge et al. (2010) também apresentam uma abordagem para reconstrução de telhados com base em modelos, considerando os edifícios como uma montagem de estruturas urbanas simples extraídas de uma biblioteca de modelos 3D. Primeiramente, a projeção horizontal do telhado é determinada de forma automática. Em seguida, blocos 3D são ajustados à base 2D por meio do modelo Gibbs. Com uma decisão *bayesiana* encontrou a configuração ideal de blocos 3D usando a cadeia Markov.

#### 2.2.2.2 Detecção de planos

Esta abordagem consiste em analisar regiões da nuvem de pontos e procurar pontos vizinhos que satisfaçam um critério de coplanaridade. Por exemplo, em Rottensteiner e Brieser (2003) é descrito um método no qual planos são ajustados a partes da nuvem de pontos, e depois a interseção destes planos é usada para encontrar as bordas do telhado e sua cumeeira.

Planos também são a base da abordagem proposta por Yano, Dal Poz e Mendes (2013). Neste trabalho, os autores propõem uma metodologia para a identificação das faces de telhados a partir de dados LIDAR, com base no método RANSAC (*RANdom SAmple Consensus*). Esse método é baseado em modelos hipotéticos previamente fornecidos para detectar objetos correspondentes como:

planos, esferas, cilindros e cones. O método RANSAC é muito popular para a detecção e modelagem de planos. Yano e Dal Poz (2016) também se baseiam em RANSAC para segmentar planos. Estes planos são analisados quanto a proximidade e orientação, a fim de fazer a junção dos segmentos planares espacialmente próximos e paralelos, pois a segmentação via RANSAC pode gerar resultados fragmentados. Outro exemplo similar é descrito por Galvanin, Dal Poz, Souza (2008) ou Kada e McKinley (2009).

Uma maneira diferente de aproximar os planos de um telhado é descrita em Botelho e Centeno (2007). O método inicia-se com a determinação das bordas externas do telhado, as quais são aproximadas por retas. Nesta fase é utilizada a transformada de Hough para detectar as retas, e a morfologia matemática para o afinamento das bordas. São aplicadas regras topológicas para procurar linhas paralelas ou perpendiculares. Estas retas são a base para a estimativa dos planos do telhado, assumindo que a declividade dos planos é perpendicular às bordas. A interseção dos planos resultantes é usada aqui também para definir a cumeeira.

#### 2.2.2.3 Crescimento de regiões em uma grade raster

Com a finalidade de reduzir o volume de dados da nuvem de pontos, Jochem et al. (2012), propuseram a utilização de uma grade raster no lugar da estrutura vetorial da nuvem de pontos. Para isto, eles propõem dividir a área de estudo em células, com superposição, para efetuar a análise de forma mais rápida. Em cada célula, uma grade raster é usada e os pontos da nuvem (XYZ) projetados nela. Em seguida, um algoritmo de detecção de regiões candidatas a elementos do telhado é aplicado para cada bloco, o que resulta na identificação de áreas potenciais contendo edifícios. Estas regiões candidatas são posteriormente combinadas e os elementos de um mesmo telhado fundidos para compor o modelo do telhado. A vantagem desta abordagem é a redução do volume de dados.

#### 2.2.2.4 Crescimento de regiões em uma estrutura TIN (*Triangulated Irregular Network*)

Os elementos de um telhado também podem ser analisados com base na triangulação de Delaunay aplicada à nuvem de pontos. Sampath e Shan (2010) apresentaram uma solução para a segmentação e reconstrução de telhados

poliédricos, baseada apenas nos dados LIDAR. A vizinhança de um ponto é determinada com base na triangulação e a variação dos triângulos no espaço serve como base para analisar se estes pontos se encontram em uma região plana ou não. Os vetores normais dos triângulos são agrupados pelo método *fuzzy k-means* para definir os planos dos telhados. Para otimizar este processo é necessário estimar o número de agrupamentos, considerando sua geometria e a topologia. Assim, os segmentos paralelos e coplanares são separados com base em suas distâncias e conectividade, respectivamente. Na fase de reconstrução é construída uma matriz de adjacência que representa a conectividade dos segmentos planos. Cada vértice interno do telhado é determinado pela intersecção dos segmentos planos, enquanto restrições na forma de paredes verticais ou limites são aplicadas para determinar os vértices do contorno da edificação. Finalmente os limites exteriores do objeto são analisados e regularizados para alcançar modelos de construção topologicamente consistentes e geometricamente corretos.

### 2.2.3 Análise de arestas

Kim e Shan (2011) apresentaram uma abordagem para modelagem de telhado a partir de dados LIDAR, em que é realizada uma segmentação pela minimização de uma função energia formulada como conjunto de nível multifásico. Os cumes e arestas foram delimitados pela união dos contornos nível zero das funções de ajuste de nível. Para reconstruir um modelo de telhado 3D, os pontos da estrutura do telhado foram determinados pela interseção de segmentos adjacentes ou segmentos de linhas dos limites das edificações e, em seguida, conectados com base em suas relações topológicas inferidas a partir do resultado da segmentação.

### 2.2.4 Outros métodos

Kabolizade, Ebadi e Mohammadzadeh (2012) apresentaram um método de reconstrução baseado em algoritmos genéticos por meio da otimização da altura e inclinações da empena de telhados. O algoritmo proposto consiste em três etapas: na primeira, os limites da construção foram detectados; na segunda, os contornos da construção são generalizados e as edificações extraídas; na terceira etapa, um método baseado em algoritmos genéticos é usado para reconstruir os modelos de

edificação, procurando os planos que mais se aproximam da nuvem de pontos através de uma função de adequação que considera a distância entre o modelo proposto e a nuvem de pontos.

#### 2.2.5 Contextualização da pesquisa

Pela revisão de literatura apresentada, observa-se uma grande variedade de métodos e combinações para a modelagem de telhados. Embora grande parte dos métodos originalmente propostos busquem reduzir o esforço computacional ao utilizar uma grade raster para representar os dados XYZ provenientes do levantamento LIDAR, ao longo do tempo os algoritmos propostos avançam cada vez mais na exploração da estrutura vetorial. Isto se deve, em grande parte, ao avanço nos recursos de informática (*hardware*), pois estes avanços possibilitam a execução de tarefas mais rapidamente e com um volume de dados maior.

Uma das tendências verificadas é a aproximação da forma do telhado assumindo que o mesmo é composto por planos. Assim sendo, grande parte dos trabalhos parte da segmentação da nuvem de pontos em planos e a posterior interseção dos mesmos para obter a descrição dos pontos mais notáveis do telhado. Como crítica para algumas destas abordagens, se questiona a necessidade de conhecimento “a priori” a respeito do número de planos a serem detectados. Isto presuppõe a satisfação de hipóteses a respeito da forma do telhado, o que restringe seu uso para formas complexas.

Dentro deste panorama, a presente pesquisa pode ser incluída no grupo de algoritmos que utilizam apenas os dados LIDAR a respeito da geometria. Não será usada a informação espectral. A abordagem proposta segue a linha de pesquisa de Kim e Shan (2011) no que se refere ao elemento básico para a modelagem, que são as arestas do telhado. A principal diferença é que existe a necessidade de verificar a aproximação de regiões da nuvem de pontos por planos. Como em Kabolizade, Ebadi e Mohammadzadeh (2012), a solução é buscada com algoritmos genéticos, mas a diferença do que estes autores propõem, a função objetivo não está associada aos melhores planos do telhado, mas sim às arestas mais representativas.

## 2.3 ALGORITMOS GENÉTICOS

Os algoritmos genéticos (AGs) são um conjunto de regras e procedimentos lógicos que simulam os processos de evolução biológica e utilizam conceitos provenientes do princípio de seleção natural para abordar uma série ampla de problemas, em especial de otimização. Os AGs são robustos, genéricos e facilmente adaptáveis, o que facilita sua utilização em diferentes áreas.

Segundo Mitchell (1995), os AGs foram primeiramente propostos por John Holland na década de 60 e desenvolvidos por ele juntamente com seus alunos e colegas da Universidade de Michigan nas décadas de 60 e 70. O objetivo de Holland foi compreender como o fenômeno da "adaptação" ocorre na natureza, para desenvolver maneiras em que os mecanismos de adaptação natural poderiam ser importados para sistemas de computador.

Ao longo dos anos de 1950 e 1960, alguns cientistas da área de computação estudaram as técnicas evolucionárias, envolvendo operadores inspirados na genética e solução natural, para que se tornassem uma alternativa como ferramenta de otimização para a resolução de problemas de engenharia (MITCHELL, 1998). O conceito da evolução natural é aplicado à computação para a resolução de problemas, pois os mecanismos de evolução parecem se adequar aos problemas computacionais nas mais variadas áreas (MITCHELL, 1998). Neste contexto, pode-se verificar a existência de uma grande variedade de modelos computacionais propostos que simulam os mecanismos de evolução natural das espécies, onde a partir de operadores genéticos como seleção, cruzamento, mutação e avaliações de indivíduos segundo seu desempenho num determinado ambiente, novas espécies e gerações são criadas (LINDEN, 2006).

Dentre as muitas aplicações dos AGs nas mais diversas áreas científicas, pode-se citar: problemas de otimização; desenvolvimento de estratégias e fórmulas matemáticas; reconstrução de objetos; análise de modelos econômicos; problemas de engenharia; simulação de bactérias; sistemas imunológicos; ecossistemas; formato e propriedades de moléculas orgânicas; entre outros.

De acordo com Pozo et al. (2005), o ponto de partida para a utilização de um algoritmo genético como ferramenta para solução de problemas é a representação destes problemas de maneira que os AGs possam trabalhar adequadamente sobre eles. Assim, uma das principais formas é representar cada atributo como uma



sequência de bits, e o indivíduo como a concatenação das sequências de bits de todos os seus atributos.

### 2.3.1 Indivíduos

Segundo Lucas (2002), os indivíduos são a unidade fundamental de um AG. Eles codificam possíveis soluções para o problema a ser resolvido e é através de sua manipulação, pelo processo de evolução, que são encontradas respostas.

Existem diversas maneiras para a representação de indivíduos em um AG. A escolha de representação para os indivíduos é arbitrária e a etapa mais importante para o desenvolvimento de um AG, pois será a principal responsável pelo desempenho do programa.

A representação utilizada mais comumente, que é também a representação proposta por Holland, é a representação binária de tamanho fixo, sendo cada indivíduo formado por uma cadeia de bits que podem assumir os valores 0 ou 1 (HINTERDING, 2000). Esta representação possui vantagens, como por exemplo, ser uma representação compacta e facilitar os operadores genéticos cruzamento e mutação. Porém, apresenta diversos outros problemas, podendo-se destacar a dificuldade para a representação de valores contínuos, que para ter uma solução, torna necessária a introdução de transformações ou discretizações no AG, representando um maior custo a sua execução (SANTOS, 2008). Neste trabalho, o indivíduo é formado por uma cadeia de bits que podem assumir valores numéricos, não necessariamente zeros e uns.


É comum na área de computação evolucionária (CE) utilizar os termos “genoma” e “cromossomo” como um sinônimo para indivíduo. A computação evolucionária é o ramo de pesquisa emergente da Inteligência Artificial que propõe um novo paradigma para solução de problemas inspirado na Seleção Natural, e que compreende um conjunto de técnicas de busca e otimização inspiradas na evolução natural das espécies. Segundo Lucas (2002), essa definição sugere que um indivíduo se resume ao seu genótipo (conjunto de genes que possui), e apresenta o problema de ter toda avaliação baseada em seu fenótipo (conjunto de características observáveis no objeto resultante do processo de decodificação dos genes), apesar de toda representação por parte do algoritmo ser baseada única e exclusivamente em seu genótipo.

A seguir, na Tabela 2, é apresentado um exemplo de genótipos e fenótipos correspondentes a um problema simples: determinar qual é o menor número de pontos que melhor descreve os contornos de um retângulo. Pode-se observar que a representação ideal do retângulo está na cor azul, e a solução proposta se encontra na cor vermelha. O problema de otimização pode ser formulado da seguinte maneira:

Seja o conjunto de pontos com coordenadas (X,Y) localizados nas bordas de um retângulo  $P: \{ (2,2); (4,2); (5,2); (7,2); (7,8); (7,12); (5,12); (2,12); (2,6); (2,2) \}$ , encontrar o menor conjunto de pontos que definem o contorno do retângulo.

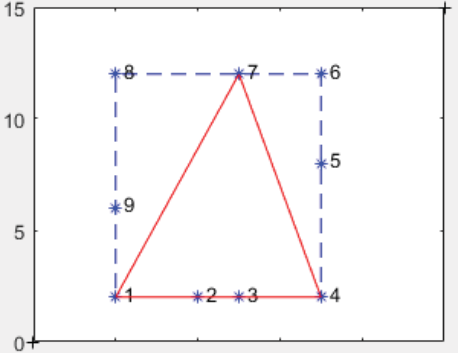
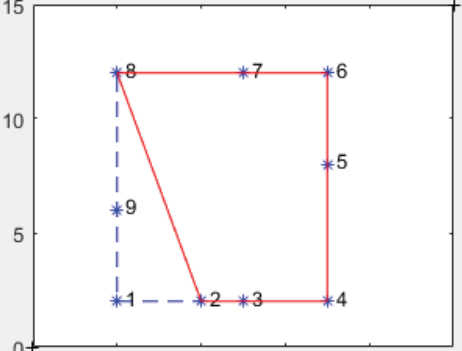
O genótipo, neste caso, pode representar uma cadeia binária contendo a informação de que o ponto faz parte da solução (1) ou não (0). A cadeia, por tanto, terá o tamanho igual ao número de pontos disponíveis, neste caso 9. Como pode-se observar na Figura 1, a escolha de 4 dos 9 pontos, destacados com círculos vermelho, gera uma aproximação do retângulo, sendo possível, através de um algoritmo de otimização, buscar o conjunto de pontos que melhor represente a forma do retângulo (com dimensão 5x10).

FIGURA 1 – REPRESENTAÇÃO GRÁFICA DO RETÂNGULO IDEAL E OS PONTOS QUE MELHOR REPRESENTAM SUA MODELAGEM.



FONTE: A autora (2018).

TABELA 2 – EXEMPLOS DE GENÓTIPOS E FENÓTIPOS CORRESPONDENTES A UM PROBLEMA SIMPLES: DETERMINAR QUAL É O MENOR NÚMERO DE PONTOS QUE MELHOR DESCREVE OS CONTORNOS DE UM RETÂNGULO.

Genótipo	Fenótipo	Pontos	Área do vermelho	Percentagem de área em relação ao retângulo
101100100		(1, 3, 4, 7)	25	50%
010101010		(2, 4, 6, 8)	40	80%

FONTE: A autora (2018).

### 2.3.2 Populações

Segundo Pozo et al. (2005), a população de um AG é o conjunto de indivíduos que estão sendo cogitados como solução e que serão usados para criar o novo conjunto de indivíduos para análise. O tamanho da população pode influenciar no desempenho global e na eficiência dos AGs. Quando se tem populações bem pequenas, são grandes as chances de perder a diversidade necessária para convergir a uma boa solução, pois fornecem uma pequena cobertura do espaço de busca do problema. Porém, quando se tem uma população grande, o algoritmo pode perder boa parte de sua eficiência devido à demora em avaliar a função de aptidão de todo o

conjunto a cada iteração, além de ser necessário trabalhar com maiores recursos computacionais (POZO et al., 2005).

A evolução só é possível devido à dinâmica populacional. De acordo com Lucas (2002), ao propagar características desejáveis a gerações subsequentes (cruzamento) enquanto novas são testadas marginalmente (mutação), um AG manipula a frequência com que determinadas sequências de genes aparecem nas populações sobre as quais atua.

### 2.3.3 Funcionamento dos AGs

Na natureza, indivíduos de uma mesma população competem entre si, buscando principalmente a sobrevivência, seja através da busca de recursos como alimento, ou visando a reprodução. Indivíduos mais aptos terão um maior número de descendentes, ao contrário dos indivíduos menos aptos (POZO et al., 2005). Os AGs trabalham com um conjunto de soluções submetido ao princípio da sobrevivência dos indivíduos mais aptos para, dessa forma, encontrar uma solução cada vez melhor.

A ideia básica do funcionamento dos AGs é tratar as possíveis soluções do problema como *indivíduos* de uma *população*, que evoluirá a cada iteração ou *geração*, e para isso é necessário construir um modelo de evolução em que os indivíduos sejam soluções de um problema (POZO et al., 2005).

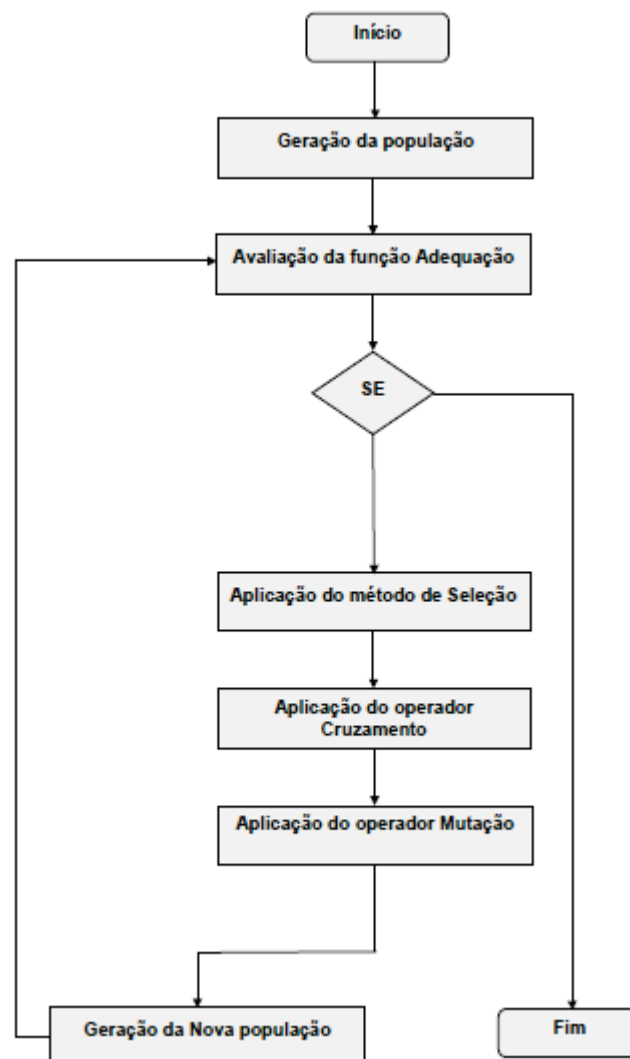
Pode-se dizer que os AGs são uma técnica heurística de otimização baseada no processo biológico da evolução natural, tendo como diferencial a capacidade de não se restringir a máximos locais, explorando o espaço de busca como um todo (SANTOS, 2008). Holland, baseado na forma que Darwinismo explica o processo de evolução das espécies, dividiu o funcionamento dos AGs nas seguintes etapas: inicialização; avaliação; seleção; cruzamento; mutação; atualização; e finalização.

A execução do algoritmo pode ser resumida da seguinte maneira: determina-se uma população inicial, geralmente formada por indivíduos aleatórios; avalia-se toda a população segundo um critério determinado por uma função que avalia a qualidade do indivíduo, chamada de *função de adequação*; são escolhidos os indivíduos de melhor valor através operador de seleção, como base para a criação de um novo conjunto de possíveis soluções, chamado também de "nova geração", que por sua vez, é obtida aplicando-se operações de *cruzamento* e *mutação* sobre os indivíduos selecionados misturando suas características. Essas etapas sofrem repetições até

que: uma solução aceitável seja encontrada; seja atingido o número predeterminado de passos; ou caso não seja mais possível ao algoritmo melhorar a solução encontrada. O processo de geração de populações através de AGs para chegar à solução mais adequada na resolução de um problema específico, utilizando o *fitness* de um cromossomo/indivíduo, pode ser chamado convergência (COX, 2005).

A Figura 2 apresenta o fluxograma do algoritmo que rege o processo iterativo.

FIGURA 2 – FLUXOGRAMA DO ALGORITMO QUE REGE O PROCESSO ITERATIVO.



FONTE: A autora (2018).

Para dar início ao processo, algumas variáveis são, a princípio, determinadas no algoritmo, como: o número de indivíduos que conforma a população; a quantidade de

pontos que conformam a solução, o que determina o tamanho da cadeia genética; o percentual de mutação e cruzamento; e o método de seleção.

- i. Para a geração da população inicial, um conjunto de pontos será selecionado arbitrariamente para cada indivíduo/solução.
- ii. Cada indivíduo da população será submetido ao teste de adequação, do qual será derivado um valor entre zero e um, descrevendo sua adequação ao problema.
- iii. Se a adequação do indivíduo mais apto for considerada suficiente, então o processo é detido já tem-se a solução. Caso contrário deve se proceder a efetuar:
  - a) Seleção de pares para o cruzamento;
  - b) Cruzamento;
  - c) Mutação;
  - d) Substituição da velha população pela nova.
- iv. Repetição dos passos ii e iii.

#### 2.3.3.1 Inicialização

Segundo Lucas (2002), a inicialização de um AG se resume à síntese de uma população inicial, sobre a qual serão aplicadas as ações dos passos subsequentes do processo. Geralmente usam-se funções aleatórias para a geração dos indivíduos, sendo um recurso simples com o objetivo de fornecer maior diversidade, e fundamental para garantir uma boa abrangência do espaço de pesquisa. Pode-se destacar, como exemplo, o uso de algoritmos de busca heurística como geradores de populações iniciais, principalmente quando há um alto grau de restrições, em que o AG recebe uma população que ainda não possui indivíduos ótimos, mas que apresentam pelo menos algumas das características desejadas (LUCAS, 2002).

Segundo Goldberg (1989) e Geyer-Shult (1997), os operadores de inicialização mais tradicionais são: *inicialização randômica uniforme*, em que cada gene do indivíduo receberá como valor um elemento do conjunto de alelos (conjunto de valores que um gene pode assumir), obtido de forma aleatória e uniforme; *inicialização randômica não uniforme*, em que alguns valores a serem armazenados no gene tendem a ser escolhidos com uma frequência maior do que o restante, e; *inicialização randômica com “dope”*, em que indivíduos otimizados são inseridos na população

gerada aleatoriamente, esta alternativa apresenta o risco de fazer com que um ou mais super-indivíduos tendam a dominar no processo de evolução e causar o problema de convergência prematura (LUCAS, 2002).

#### 2.3.3.2 Função de Adequação

O AG é uma busca dirigida controlada pela função de adequação. Entende-se que este é o componente mais importante de qualquer AG. É por meio da função de avaliação que se determina a qualidade de um indivíduo ou valor de aptidão deste, ou o quão próximo está da solução desejada ou o quão boa é esta solução. Assim, obtido este valor, e através do método de seleção, os indivíduos melhor avaliados são escolhidos para reprodução.

É essencial que esta função seja representativa e diferencie, na proporção correta, as soluções boas das ruins. Se houver pouca precisão na avaliação, uma solução ótima pode ser ignorada durante a execução do algoritmo, além de um gasto de tempo maior voltado à exploração de soluções pouco promissoras (POZO et al., 2005).

Em geral, calcular com exatidão o grau de adaptação dos indivíduos pode ser uma tarefa complexa, e levando em consideração que esta operação é repetida diversas vezes ao longo do processo de evolução, o custo pode se tornar consideravelmente alto. Nestas situações é comum o uso de funções não determinísticas, que avaliam com base numa amostragem das características do indivíduo, e não sua totalidade (LUCAS, 2002).

Considerando o exemplo dado na Tabela 2 (pg. 32), o desempenho de cada indivíduo, sua adequação à solução do problema deve ser quantificada para escolher o indivíduo mais apto. Uma forma de avaliação poderia ser pela verificação do valor de área do polígono solução em relação à área do retângulo em azul. Considerando a percentagem de área obtida por cada solução, a primeira solução (101100100) teria um valor de desempenho igual a 50%. Já a segunda solução proposta teria uma adequação melhor, de 80%.



### 2.3.3.3 Seleção

A seleção de indivíduos é a parte do AG que é responsável pela propagação de boas características na espécie. Neste passo são selecionados indivíduos da população para reprodução e favorece aqueles com maior *adequação*, ou seja, quanto melhor a avaliação do indivíduo, mais vezes pode ser selecionado para se reproduzir.

De acordo com Santos (2008), a *seleção* simula o mecanismo de seleção natural, em que os pais mais aptos geram mais filhos e pais menos aptos podem gerar menos descendentes. Os indivíduos menos aptos não podem ser totalmente descartados, para que seja evitada a convergência genética, em que os indivíduos se tornam cada vez mais semelhantes, destroem a diversidade da população e comprometem a evolução.

Segundo Dawkins (1996), a seleção é um processo *dirigido*, pois opera de forma determinística ou próximo disso, ou seja, enquanto as mutações ocorrem ao acaso, um indivíduo só consegue sobreviver em um ambiente e nele se reproduzir se e somente se for capaz, graças às suas características fenotípicas, de responder de forma adequada a todos os fenômenos de seu meio, e também um processo *cumulativo*, pois os benefícios da seleção são mantidos de uma geração para a outra. Este fato, combinado com a não aleatoriedade da seleção, garante a possibilidade do surgimento de organismos complexos. Então, a seleção natural consiste de um longo processo de pequenas tentativas e erros, em que os ganhos são sempre acumulados de geração para geração (LUCAS, 2002).

É na etapa de seleção que os indivíduos são escolhidos para um posterior cruzamento. Dada uma população em que para cada indivíduo foi atribuído um valor de aptidão, existem vários métodos para selecionar os indivíduos sobre os quais serão aplicados os operadores genéticos. Há diversas formas de seleção, entre eles, seleção por *ranking* (*rank selection*), seleção uniforme, *remainder stochastic selection*, porém os mais utilizados são seleção por Roleta e por Torneio.

Na seleção por Roleta é criada uma roleta, onde cada indivíduo ou cromossomo recebe uma parte proporcional ao seu *fitness* em relação à soma total dos *fitness* de todos os indivíduos da população (SANTOS 2008), assim, cada indivíduo da população é representado na roleta proporcionalmente ao seu índice de aptidão.


A Tabela 3 juntamente com a Figura 3 mostra um exemplo com alguns indivíduos fictícios e a representação da roleta para eles:

TABELA 3 – GRUPO ALEATÓRIO DE INDIVÍDUOS, SEUS RESPECTIVOS *FITNESS* E PARCELA NA ROLETA.

Indivíduo	Fitness	Pedaço da roleta (%)	Pedaço da roleta (°)
11	3	8,33	30
111	7	19,44	70
1011	11	30,55	110
1111	15	41,66	150
<b>Total</b>	36	100	360

FONTE: A autora (2018).

FIGURA 3 – EXEMPLO DA ROLETA PARA O CASO DA TABELA 3.

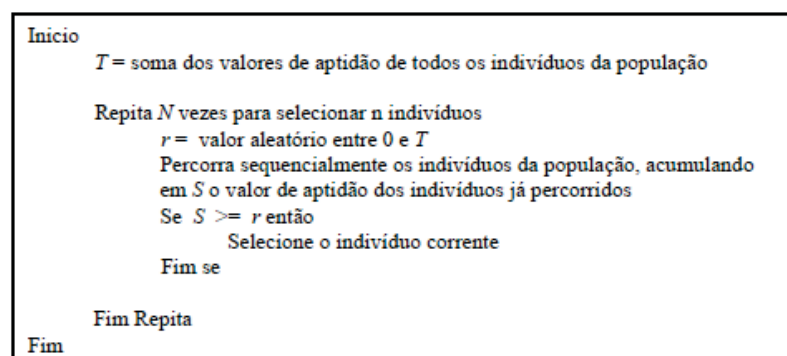


FONTE: O autor (ano).

A representação da roleta acima é dada por um algoritmo que não permite a existência de indivíduos com avaliação negativa ou igual a zero, pois não possuiriam nenhuma parcela da roleta e nunca seriam selecionados (SANTOS 2008).

A lógica do algoritmo da roleta é descrita na Figura 4.

FIGURA 4 – ALGORITMO BÁSICO DO MÉTODO DE SELEÇÃO POR ROLETA.



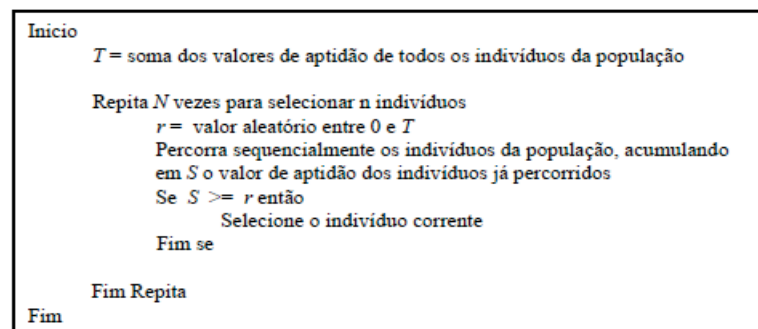
FONTE: Pozo et. al. (2002).

De acordo com Pozo et al. (2005), neste método, um dos problemas encontrados pode ser o tempo de processamento, já que o método exige duas passagens por todos os indivíduos da população.

Já na seleção por Torneio, um número  $n$  de indivíduos da população é escolhido aleatoriamente para formar uma sub-população temporária. Deste grupo, o indivíduo selecionado dependerá de uma probabilidade  $k$  definida previamente (POZO et al., 2005), ou seja, o mais apto é selecionado. Geralmente, quanto maior o número de repetições, maior a probabilidade de convergência genética, resultante da extinção dos indivíduos menos aptos da população.

Um exemplo simples da implementação deste algoritmo é mostrado na Figura 5, onde  $n=2$ :

FIGURA 5 – ALGORITMO BÁSICO DO MÉTODO DE SELEÇÃO POR TORNEIO.



FONTE: Pozo et. al. (2002).

Este método é o mais utilizado, pois oferece a vantagem de não exigir que a comparação seja feita entre todos os indivíduos da população.

Os indivíduos selecionados passam pelo processo de *cruzamento* (crossover) com uma probabilidade pré-estabelecida, onde os genes dos indivíduos selecionados são combinados para geração de novos indivíduos. De acordo com (LUCAS, 2002), alguns dos principais métodos de escolha dos pares reprodutores (Pareamento ou Mating) são, segundo (GEYER-SCHULTZ, 1997): *escolha aleatória*, onde os pares reprodutores são escolhidos ao acaso; *inbreeding*, onde parentes são combinados; *line breeding*, onde um indivíduo de alta performance é cruzado com uma subpopulação de indivíduos e os filhos são selecionados como pais; *outbreeding*, onde indivíduos que codificam fenótipos diferentes são combinados; *self-fertilization*, onde o indivíduo é combinado consigo mesmo; *positive assortive mating*, onde

indivíduos semelhantes são combinados; *negative assortive mating*, onde indivíduos diferentes são combinados.

#### 2.3.3.4 Operadores genéticos

O princípio de um operador genético é transformar a população através de sucessivas gerações, estendendo a busca da solução ótima até chegar a um resultado satisfatório. Os operadores genéticos são necessários para que a população se diversifique e mantenha características de adaptação adquiridas pelas gerações anteriores (POZO et al., 2005). Os operadores de *cruzamento* e de *mutação* são essenciais em um AG, devido à sua responsabilidade por todas as transformações sofridas pela população, mas possuem funções bastante distintas no que diz respeito a seu impacto na evolução.

##### 2.3.3.4.1 Cruzamento

O processo de criação de um novo indivíduo através da combinação de dois indivíduos pais, também chamados de cromossomos de alta performance, é conhecido como cruzamento, e considerado o operador genético predominante. Esta mistura de características é feita na tentativa de imitar, em certo nível de abstração, a reprodução de genes em células. O cruzamento garante a troca de material genético entre dois indivíduos pais, onde trechos das características de um indivíduo são trocados pelo trecho equivalente do outro, combinando informações de maneira que haja uma probabilidade razoável dos indivíduos resultantes serem melhores que os pais.


Graças ao operador de cruzamento e à função de avaliação, os AGs são classificados como uma busca dirigida, pois utilizam a seleção para determinar as áreas mais promissoras de pesquisa e cruzamento para combiná-las de modo a gerar soluções mais aptas para resolução do problema em questão (LINDEN, 2006).

O objetivo do operador cruzamento é propagar os esquemas mais adequados na população, portanto, os pontos de corte são fundamentais, pois determinarão quais esquemas sobreviverão ao processo de reprodução. Em problemas altamente combinatórios um operador cego de cruzamento pode facilmente gerar filhos menos

adequados a partir dos cromossomas pais, fenômeno causado por uma alta correlação entre genes (LUCAS, 2002).

Alguns tipos de cruzamento bastante utilizados são: *cruzamento em um ponto*; e o *cruzamento em dois pontos*. No *cruzamento em um ponto* são selecionados dois pais utilizando um método de seleção, e então é escolhido um ponto de corte (posição entre dois genes de um cromossomo). Com o ponto de corte definido, tem-se os pais separados em duas partes. Cada um dos dois filhos recebe parte da informação genética de cada um dos pais, da seguinte maneira: um dos filhos é obtido concatenando-se a parte que se encontra à esquerda do ponto de corte do primeiro pai à parte que se encontra à direita do segundo pai; e o outro filho é obtido concatenando-se a parte que se encontra à esquerda do segundo pai à parte que se encontra à direita do primeiro pai. Esse processo está representado na Figura 6. No caso desse trabalho, pode-se observar como são os indivíduos de acordo com a Tabela 2 (pág. 32), e o ponto de corte é determinado como sendo o centro do gene, dividindo o gene igualmente em duas partes, porém caso o gene possuía número ímpar, é escolhido o ponto de corte deixando o gene central na primeira parte da divisão.

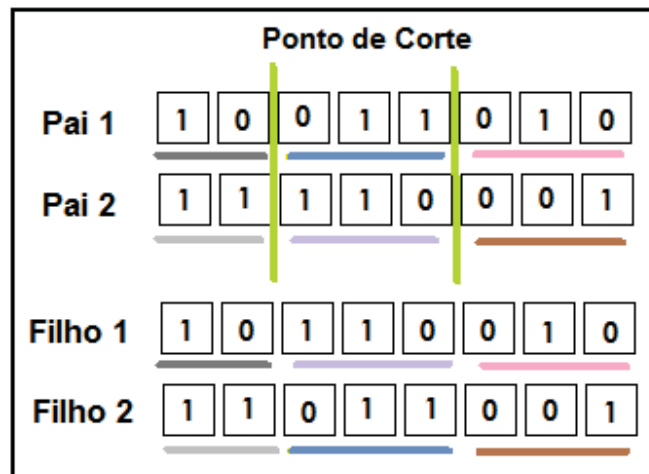
FIGURA 6 – CRUZAMENTO EM UM PONTO.



FONTE: A autora (2018).

No *cruzamento em dois pontos*, diferentemente do cruzamento citado acima, são escolhidos dois pontos de corte. Assim, um dos descendentes fica com os genes centrais do primeiro pai e os genes dos extremos do segundo pai, e o outro descendente fica com os genes centrais do segundo pai e os genes dos extremos do primeiro, como representado na Figura 7.

FIGURA 7 – CRUZAMENTO EM DOIS PONTO.




FONTE: A autora (2018).

Já em outra forma de cruzamento, chamada *crossover uniforme*, cada gene possui igual probabilidade de ser trocado independente de sua posição, assim, para cada gene a ser preenchido nos cromossomos filhos, o operador de cruzamento uniforme sorteia de qual dos pais este deve ser gerado. O cruzamento uniforme é poderoso para AGs que utilizam a representação binária de cromossomos, pois criam soluções que os outros tipos de cruzamento não conseguem criar.


É possível representar o funcionamento dos operadores de cruzamento como uma seleção por máscara, esta seria representada por um vetor cujos elementos possam assumir valores binários e que possua um comprimento igual ao dos cromossomas a serem combinados (LUCAS, 2002). Seu uso pelo operador se daria segundo o modelo apresentado na Figura 8, tendo seu algoritmo ilustrado na Figura 9. No caso deste trabalho o programa escolhe o primeiro indivíduo pela sequência como o pai.

FIGURA 8 – CRUZAMENTO UNIFORME.



FONTE: A autora (2018).

FIGURA 9 – ALGORITMO DE UMA MÁSCARA DE CRUZAMENTO.




FONTE: A autora (2018).

#### 2.3.3.4.2 Mutação

A mutação modifica aleatoriamente alguma característica do indivíduo sobre o qual é aplicada alterando sua estrutura. Esta operação pode ocorrer em cada gene de um cromossomo com uma probabilidade informada pelo usuário, ou baseada em algum critério definido previamente. Esta troca é importante, pois acaba por criar novos valores de características que não existiam ou apareciam em pequena quantidade na população em análise (POZO et al., 2005). Na Figura 10 pode-se observar um modelo de mutação simples.

FIGURA 10 - ILUSTRAÇÃO DA MUTAÇÃO SIMPLES.



FONTE: A autora (2018).

O operador de mutação é necessário para a introdução e manutenção da diversidade genética da população. Além do propósito de manter a diversidade dessa população, deve assegurar que o cromossomo cobrirá uma grande parte do espaço de busca, introduzindo material genético que não está presente em nenhum outro

indivíduo da população, ao contrário do operador de cruzamento (CARVALHO, 2005). Desta forma, a mutação garante que a probabilidade de se chegar a qualquer ponto do espaço de busca possivelmente não será zero, além de diversificar a população e combater as regiões de mínimos e máximos locais.

Segundo Lucas (2002), o operador de mutação possui também um papel fundamental no que diz respeito à necessidade de evitar a convergência prematura, que ocorre quando a população se estabiliza com uma média de adaptação pouco adequada devido a pressão evolutiva e baixa diversidade. Isto geralmente se dá com o surgimento de um super-indivíduo que domina o processo seletivo e, uma vez incapaz de gerar filhos melhores, transmite suas características por toda população (LUCAS, 2002).

#### 2.3.3.5 Atualização

Nesta etapa, os indivíduos resultantes dos processos de *cruzamento* e *mutação* são inseridos na população, atualizando-a. Em um AG simples, como é o caso desse trabalho, a população mantém um tamanho fixo, os indivíduos são criados em mesmo número que seus antecessores e os substituem por completo. Porém existem alternativas para essa abordagem: o número de indivíduos gerados pode ser menor; o tamanho da população pode sofrer variações; o critério de inserção pode ser variado; ou o conjunto dos  $n$  melhores indivíduos pode sempre ser mantido - elitismo (LUCAS, 2002).

##### 2.3.3.5.1 Elitismo

O elitismo tem como objetivo preservar indivíduos com altos valores de *fitness* por mais de uma geração, copiando-os para a geração seguinte. Tendo uma população com  $N$  indivíduos, são escolhidos  $N_{el}$  indivíduos com os melhores *fitness*. O número  $N_{el}$  é chamado de fator de elitismo, definido pelo usuário e geralmente pequeno. Estes indivíduos são copiados integralmente para a população da próxima geração do AG. Os outros  $N - N_{el}$  indivíduos da nova população são gerados a partir da aplicação dos operadores genéticos seleção, cruzamento e/ou mutação (CARVALHO, 2005).



Esta opção de funcionamento é amplamente utilizada, normalmente com apenas um indivíduo compondo a elite, mesmo em AGs simples. Deve ser aplicada com cuidado para evitar o problema da convergência prematura (LUCAS, 2002).

#### 2.3.3.6 Finalização

A etapa consiste em um teste que dá fim ao processo de evolução. Os critérios para a parada podem ser vários, como o número de gerações criadas, o grau de convergência da atual população, entre outros (LUCAS, 2002). No caso deste trabalho, o fator limitante é número de iterações determinado. Essa etapa não apresenta a avaliação da qualidade dos resultados, somente finaliza o processo e mostra os resultados.

### 3 MATERIAL E MÉTODOS

Na realização dessa pesquisa foram utilizados os softwares MatLab e LAStools.

O MatLab é um software interativo de alta performance voltado para o cálculo numérico. Integra análise numérica, cálculo com matrizes, processamento de sinais e construção de gráficos em ambiente de fácil utilização. Foi usado para o desenvolvimento e implementação dos algoritmos desse trabalho.

O processo de modelagem de telhados não é possível sem uma primeira fase de detecção ou classificação de construções/edificações, vegetação e solo. Para isto, encontra-se na literatura diversas opções, sendo algumas disponíveis em software como o *ALDpat* e o *Lastools*, sendo esse último utilizado nessa pesquisa.

O LAStools é um software que disponibiliza diversas funções para a manipulação de nuvem de pontos. No caso desse trabalho, o software foi utilizado para o recorte da nuvem de pontos, selecionando somente telhados determinados, que foram utilizados para a realização dos experimentos. Esta etapa não será tratada nesse trabalho. O estudo pressupõe que a construção foi previamente classificada e a tarefa a ser resolvida é a modelagem de sua forma.

A metodologia proposta foi dividida nas etapas apresentadas abaixo e serão explicadas a seguir:

- v. Definição do problema;
- vi. Proposta dos algoritmos genéticos;
- vii. Proposta da função objetivo;
- viii. O algoritmo;
- ix. Avaliação.


#### 3.1 DEFINIÇÃO DO PROBLEMA

O problema a se resolver é a modelagem de telhados de faces planas, a partir de nuvens de pontos simuladas e nuvens obtidas por LIDAR aerotransportado. As nuvens de pontos obtidas por LIDAR aerotransportado foram pré-processadas utilizando-se o software LAStools, assim foi possível a separação dos telhados dos demais elementos.

Portanto, dada uma nuvem de pontos de coordenadas (X,Y,Z) pretende-se detectar aqueles pontos que melhor representam os pontos significativos (arestas)

para a representação do telhado. Como exemplo, a Figura 11a mostra uma nuvem de pontos correspondente a um telhado de duas águas. Porém, mesmo com uma alta densidade de pontos, nota-se que apenas seis deles são necessários para a definição da geometria. Já a Figura 11b mostra os seis pontos destacados em vermelho, que seriam suficientes para esta. O restante dos pontos pode ser considerado redundante, e na sua maioria são coplanares, como observado na Figura 11a. Isso se aplica da mesma maneira para telhados de quatro águas ou mais.

FIGURA 11 - EXEMPLO DE MODELAGEM DE TELHADO: (A) NUVEM DE PONTOS DE UM TELHADO (AZUL) E OS PONTOS MAIS SIGNIFICANTES (VERMELHO); (B) MODELO OBTIDO A PARTIR DOS PONTOS SIGNIFICANTES.



FONTE: A autora (2018).

Espera-se que os pontos significativos não ocorram em locais planos, e sim, nas bordas do telhado. Por este motivo, pontos localizados em regiões não planas foram procurados para dar início ao processo de busca. Para isto, foi empregado um algoritmo de detecção de bordas que analisa os autovalores da região, na triangulação.


### 3.1.1 Triangulação de Delaunay

A nuvem de pontos é um conjunto de pontos com coordenadas X, Y, Z. Embora a posição de cada ponto seja resultado do padrão de varredura, assume-se que a posição de cada ponto é independente dos seus vizinhos no arquivo de pontos. O conjunto de pontos obtidos pela varredura LIDAR que corresponde a um telhado pode ser entendido como a representação de dimensão 2 ½ do objeto, pois apenas a parte superior dele encontra-se disponível. Por isso, é considerado que não existem pontos com as mesmas coordenadas XY no conjunto. Quando isto ocorre, apenas o maior valor é considerado por assumir que ele é parte do telhado.

Para representar as relações de vizinhança dos pontos, os mesmos foram projetados no plano horizontal ( $Z=0$ ). Estes pontos podem ser ligados por segmentos de reta para formar uma malha bidimensional. Se a malha formada é composta apenas por triângulos, ela é chamada de triangulação.

Uma triangulação particular é a triangulação de Delaunay, e o critério utilizado nessa triangulação é maximizar os ângulos mínimos de cada triângulo. Já a malha atende ao critério de que o círculo formado pelos três vértices de um triângulo não contém no seu interior nenhum outro ponto do conjunto das amostras além dos vértices do triângulo em questão, como representado na Figura 12.

FIGURA 12 - EXEMPLO DE UMA TRIANGULAÇÃO DE DELAUNAY




FONTE: Adaptação de Guedes A. L.P., 1996.

As coordenadas XY dos pontos do telhado foram utilizadas para gerar uma triangulação de Delaunay. Com base na triangulação é possível então encontrar os vizinhos mais próximos de cada ponto, que são aqueles que formam triângulos onde o ponto em questão está presente.

No presente trabalho, a aproximação da forma do telhado será feita mediante uma triangulação de Delaunay entre os pontos significativos, como é exemplificado na Figura 13.

FIGURA 13 - REPRESENTAÇÃO DO TELHADO USANDO UMA TRIANGULAÇÃO: (A) EM 3D; (B) EM PLANTA.



FONTE: A autora (2018).

### 3.1.2 Detecção de bordas

A etapa de detecção de bordas é um processo importante pois influencia diretamente a modelagem de telhados. Com o intuito de obter uma descrição de características relevantes em uma nuvem de pontos, Weinmann, Jutzi e Mallet (2013) propuseram a análise da vizinhança do ponto, uma análise local, em termos de distribuição dos pontos no espaço. Para isto, a matriz variância-covariância das coordenadas tridimensionais dos pontos deve ser analisada. Os autovalores ( $\lambda_1$ ,  $\lambda_2$  e  $\lambda_3$ ) e autovetores dessa matriz podem ser utilizados para calcular descritores

espaciais, que por sua vez, são utilizados para descrever a forma da região. Isto pode ser feito, por exemplo, aplicando uma definição de vizinhança esférica onde todos os pontos dentro de uma esfera de raio fixo  $r_s$  formam a vizinhança local (LEE e SCHENK, 2002). Ou também, como alternativa, a definição de vizinhança cilíndrica pode ser aplicada levando em conta todos os pontos 3D cuja projeção 2D no plano está dentro de uma área circular de tamanho fixo  $r_c$  (FILIN e PFEIFER, 2005). Há também uma outra definição que é baseada na seleção dos  $k$  pontos 3D mais próximos que não incluem um tamanho de vizinhança espacial fixo (LINSEN e PRAUTZSCH, 2001).

Baseado na informação espacial de todos os pontos dentro de uma determinada vizinhança  $U$ , momentos invariantes representando propriedades geométricas podem ser calculados para cada ponto 3D (MAAS e VOSSSELMAN, 1999), bem como a respectiva matriz de covariância 3D ( $S$ ) (JUTZI e GROSS, 2009).

Os autovalores  $\lambda_1$ ,  $\lambda_2$  e  $\lambda_3$  da matriz de covariância  $S$ , sendo  $\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq 0$ , podem ser usados diretamente para descrever a estrutura 3D local, ou também, outras medidas baseadas nesses autovalores podem ser derivadas, as quais englobam propriedades geométricas especiais (WEST et al., 2004; TOSHEV, TASKAR e DANIILIDIS, 2010; MALLET et al., 2011).

Para descrever a dimensionalidade local, as medidas de linearidade  $L_\lambda$  e planicidade  $P_\lambda$ , fornecem informações sobre a presença de uma estrutura 1D linear, uma estrutura 2D plana ou uma estrutura 3D volumétrica. O uso da mudança de curvatura é indicada como  $C_\lambda$ . As definições matemáticas dessas medidas são fornecidas a seguir e mostram um comportamento característico, dependendo da estrutura 3D local.

$$L_\lambda = \frac{\lambda_1 - \lambda_2}{\lambda_1} \quad (3)$$

$$P_\lambda = \frac{\lambda_2 - \lambda_3}{\lambda_1} \quad (4)$$

$$C_\lambda = \frac{\lambda_3}{\lambda_1 + \lambda_2 + \lambda_3} \quad (5)$$

Além das características derivadas da matriz covariância  $S$ , existem outras medidas importantes, como a verticalidade  $V$  (DEMANTKE et al., 2012) e a densidade local  $D$ , que são definidas como:

$$V = 1 - n_z \quad (6)$$

$$D = \frac{k+1}{\frac{4}{3} \pi r_{k-NN}^3} \quad (7)$$

Sendo  $n_z$  o terceiro componente do vetor normal  $n$ , e  $r_{k-NN}$  o raio da vizinhança definida por um ponto 3D e seus  $k$  vizinhos mais próximos. Aqui, a definição da densidade de pontos locais foi adaptada da respectiva definição em 2D (LARI e HABIB, 2012).

Weinmann, Jutzi e Mallet (2013) propuseram o uso de três variáveis, conforme as equações 8, 9, 10, que servem para classificar regiões segundo a forma na nuvem de pontos.

$$\text{Regiões planas: } x_2 = \frac{\lambda_3}{(\lambda_2 * \lambda_1)} \quad (8)$$

$$\text{Objetos estreitos: } x_3 = \frac{\lambda_2}{\lambda_3} \quad (9)$$

$$\text{Volumétricos: } x_4 = \frac{\lambda_1 * \lambda_3}{\lambda_2^2} \quad (10)$$

Utilizando o critério de planicidade, proposto por Weinmann, Jutzi e Mallet (2013), foi possível identificar pontos associados a regiões planas na nuvem de pontos. Então, assumiu-se que o restante dos pontos se localiza em áreas de borda ou de elevada curvatura na superfície do telhado, o que os caracterizaria como bons candidatos para a descrição da forma do telhado.

### 3.2 PROPOSTA DOS ALGORITMOS GENÉTICOS

Após a detecção de bordas, o problema proposto deve ser representado dentro do escopo dos algoritmos genéticos para poder ser resolvido. Assim, o primeiro passo é a proposta dos algoritmos genéticos e a sua codificação.

O conjunto total de pontos  $U$  pode ser dividido em dois grupos:

- $P$ : pontos localizados em regiões de bordas;
- $Q$ : pontos localizados em regiões planas;

Sendo  $P$  o conjunto de pontos com coordenadas tridimensionais:

$$P(i) = (x_i, y_i, z_i) \in P \quad (11)$$

Busca-se o conjunto ótimo (ou sub-ótimo)  $S$ , subconjunto de  $P$ , que represente adequadamente os vértices dos planos do telhado ( $S \in P$ ), ou seja, que minimize a função objetivo:

$$F(F(S) = \min, \text{ com } S \in P) \quad (12)$$

A solução para o problema é o conjunto restrito de pontos, que estão destacados com círculos vermelhos, considerando o exemplo ilustrado na Figura 11. Como, a princípio, o número mínimo de pontos necessário para resolver o problema é desconhecido, pode-se fixar um subconjunto “ $s$ ” com uma quantidade maior de pontos do que o necessário. Um número maior de pontos do mínimo necessário não é prejudicial, pois apenas introduziria redundância no modelo.

Com base nisto, e considerando que um indivíduo deve representar uma provável solução para o problema, o indivíduo/solução do problema armazena o índice  $IN$  de cada ponto do conjunto solução  $S$ . Por exemplo, considerando o exemplo da Figura 13, o indivíduo deveria ter a posição dos seis pontos destacados em vermelho dentro da lista de pontos da nuvem de pontos. Também poderiam ser representadas as coordenadas de cada ponto, mas isto aumentaria a cadeia genética desnecessariamente.

A solução é então descrita por um vetor com os  $NP$  pontos selecionados para descrever o telhado:



$$SOL = [sol_1, sol_2, sol_3, \dots, sol_{NP}] \quad (13)$$

Sendo  $sol_i$  um dos pontos do subconjunto  $S$ , e  $sol_i \in IN$ .

O conjunto solução  $SOL$  é então representado como uma cadeia binária. O segundo conjunto de pontos  $Q$  é formado pelos pontos localizados em regiões planas ou interiores aos planos dos telhados. Este conjunto é usado para verificar a adequação de cada solução ( $SOL$ ). Para cada solução é verificado se os planos formados pelos pontos selecionados ( $sol_1, sol_2, sol_3, \dots, sol_n$ ) se aproximam dos pontos no conjunto  $Q$ . A solução procurada é aquela que melhor representa o conjunto  $Q$  com base em pontos selecionados do conjunto  $P$ :

$$Dist(T(SOL), Q) = \text{mín} \quad (14)$$

Como o conjunto  $Q$  contém grande quantidade de pontos num mesmo plano do telhado, ele é altamente redundante. Por este motivo, ao invés de verificar a hipótese em todo o conjunto  $Q$ , um subconjunto aleatório de pontos é usado para a verificação, o que torna o processo mais rápido:

$$Dist(T(SOL), PL) = \text{mín} \quad (15)$$

sendo  $PL \in Q$  e  $T$  a triangulação de Delaunay.

### 3.3 PROPOSTA DA FUNÇÃO DE ADEQUAÇÃO

A função de adequação que deve ser proposta dentro do escopo dos algoritmos genéticos, é a identificação do subconjunto  $SOL$ . Para isto, é necessário definir a representação da solução final.

A função de adequação deve identificar os pontos ( $SOL$ ) que formam a triangulação que mais se aproxima da forma do telhado, representado por  $Q$  ou  $PL$ . Isto implica que o conjunto  $PL$  está contido nos planos que o conjunto  $SOL$  define através da triangulação. Na prática isto nem sempre se verifica em função da variação das coordenadas XYZ, decorrente do processo de aquisição dos dados. Por isso, o objetivo é minimizar a distância média entre a nuvem de pontos e os planos definidos pela triangulação final:

$$Obj = \min (Dist(T(SOL), Q)), \text{ com } SOL \in P \text{ e } PL \in Q \quad (16)$$

Neste contexto, a função a ser minimizada *Dist*, deve avaliar a proximidade entre os pontos *PL* e a triangulação *T(SOL)*. Por isso, para cada solução é calculada a triangulação bidimensional com o conjunto de pontos *SOL* e uma triangulação tridimensional é construída adicionando a coordenada *Z*. Esta triangulação é dita mais simples, pois é formada por uma quantidade menor de pontos.

A similaridade entre a solução e os pontos de verificação é inversamente proporcional à diferença da média do valor absoluto da diferença entre a coordenadas *Z* dos  $N_{PL}$  pontos de verificação (*PL*) e o ponto interpolado na triangulação na mesma posição *XY*. Ou:

$$d_i (PL_i, T(SOL)) = (Z_i - ZT(X_i, Y_i)) \quad (17)$$

sendo  $X_i, Y_i, Z_i$  as coordenadas do ponto  $PL_i$ , e *ZT* o valor da altura interpolado na superfície da triangulação.

A distância média é dada por:

$$Dist = \sum_{i=1}^{N_{PL}} di(PL_i, T(SOL)) / N_{PL} \quad (18)$$

Formalmente, a função objetivo pode ser descrita como:

$$SOL = \{SOL_j\} \text{ tal que } Dist = \text{Mín} \{Dist(PL, T(SOL))\} \quad (19)$$


Dada uma possível solução ao problema (*SOL*), a avaliação da adequação da solução em cada iteração passa pelos seguintes passos:

- a) Criação de uma triangulação 2D (*T(SOL)*) a partir dos pontos considerados como solução (*SOL*).
- b) Para cada ponto da nuvem de pontos ( $P_i$ ) deve-se:
  - I. Identificar o triângulo ( $Tri_j$ ) dentro do qual o ponto  $P_i$  encontra-se inserido considerando as coordenadas *XY*;
  - II. Interpolar o valor de *Z* na superfície da triangulação tridimensional;

- III. Calcular o valor absoluto da distância entre o plano definido pelo triângulo  $Tri_j$  e ponto  $P_i$ .
- c) Calcular a média das distâncias e derivar um valor representativo, variando de zero a um.

Portanto, pode-se dizer que aqui o objetivo é: a partir de soluções aleatórias, convergir para a solução ótima do problema no processo iterativo dos algoritmos genéticos, como ilustrado na Figura 14.

FIGURA 14 - PROCESSO ITERATIVO DE APROXIMAÇÃO DE TELHADOS.



FONTE: A autora (2018).

O valor final da adequação deve representar a proximidade entre a solução e os dados. Isto pode ser medido usando uma função linear, como mostra a equação 13 (pág. 53). Nesta equação,  $max_i$  é um fator de normalização e representa a maior diferença em altura dos pontos do telhado.

$$Fitness = 1 - \frac{Dist}{max_i} \quad (20)$$

$$max_i = max_z(U) - min_z(U) \quad (21)$$

Uma alternativa consiste em penalizar mais as grandes diferenças, usando uma função quadrática ou sigmoide:

$$Fitness = 1 - \frac{Dist^2}{max_i^2} \quad (22)$$


$$Fitness = \frac{1}{\left(1 + e^{-\left(\frac{Dist}{10} - 5\right)}\right)} \quad (23)$$

Para identificar o triângulo no qual o ponto está contido é feita uma análise geométrica do ponto em relação a cada triângulo, sendo um triângulo descrito pelos seus três vértices, pontos  $S_a$ ,  $S_b$  e  $S_c$ . Dois vetores no plano podem ser obtidos conforme as equações 24 e 25 e a Figura 15.

$$V_1 = S_b - S_a \quad (24)$$

$$V_2 = S_c - S_a \quad (25)$$

FIGURA 15 - REPRESENTAÇÃO DE DOIS VETORES NUM PLANO.




FONTE: A autora (2018).

O vetor normal ao plano é dado pelo produto vetorial entre estes dois vetores, como na equação 26 e na representação na Figura 16:

$$N = V_1 \times V_2 \quad (26)$$

FIGURA 16 - REPRESENTAÇÃO DO PRODUTO VETORIAL ENTRE DOIS VETORES.




FONTE: A autora (2018).

Em um plano  $\pi$  no espaço, de vetor normal  $N = (a, b, c)$  passando pelo ponto  $P_o = (x_o, y_o, z_o)$ , e tendo um ponto  $P_i = (x, y, z)$  do espaço que está neste plano, tem-se o vetor  $P_oP_i = (x - x_o, y - y_o, z - z_o)$  perpendicular a  $N$ . Desta forma, pode-se descrever  $\pi$  como sendo o conjunto de pontos  $P_i$  do espaço que resolvem a equação vetorial:

$$N * P_oP_i = 0 \quad (27)$$

A Figura 17 abaixo mostra o a situação descrita anteriormente.

FIGURA 17 - REPRESENTAÇÃO DO VETOR NORMAL COM VETOR  $P_oP_i$ .

FONTE: A autora (2018).

Escrevendo os vetores como coordenadas, tem-se:

$$N * P_o P_i = a(x - x_o) + b(y - y_o) + c(z - z_o) \quad (28)$$

Portanto, a equação vetorial 27 (pág.57) corresponde à equação cartesiana:

$$a(x - x_o) + b(y - y_o) + c(z - z_o) = 0 \quad (29)$$

Então, tomando:

$$d = a(x_o) - b(y_o) - c(z_o) \quad (30)$$

obtem-se a chamada equação geral do plano  $\pi$ :

$$d = a(x) + b(y) + c(z) \quad (31)$$

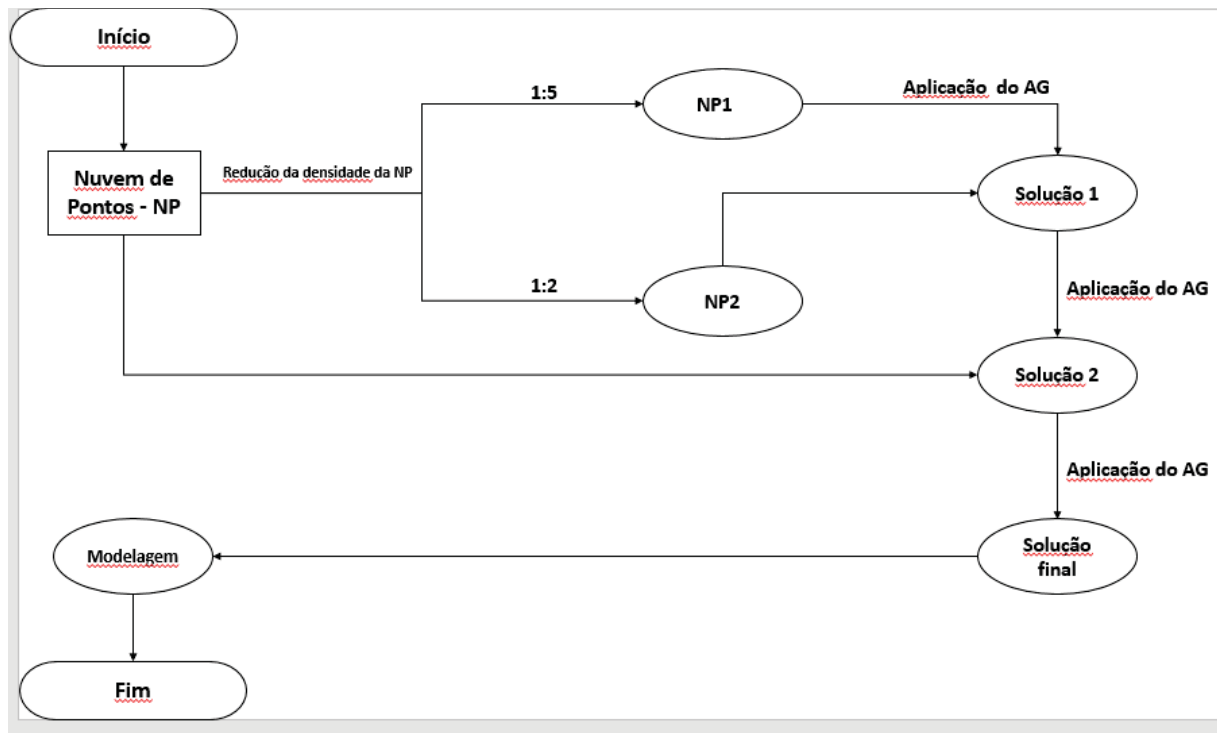
Portanto, a projeção vertical de um ponto  $P_i$  contido dentro da projeção vertical do triângulo pode ser calculada como:

$$P_{VT} = N * P_i \quad (32)$$

### 3.4 O ALGORITMO

O processamento da modelagem de telhados tem seu início na aquisição da nuvem de pontos já pré-processada. Com a obtenção de uma nuvem de pontos isolada, referente a um telhado, é realizada a detecção de bordas. A etapa seguinte consiste em aplicar as rotinas do AG para realizar a modelagem do referente telhado. A Figura 18 apresenta o fluxograma do processo de modelagem.

FIGURA 18 – FLUXOGRAMA DO PROCESSO DE MODELAGEM.



FONTE: A autora (2018).

### 3.4.1 Detecção de pontos significativos

Como apenas os pontos referentes ao telhado estão presentes, é inicialmente adicionada uma borda ao telhado, com cota zero, para representar o chão em torno do objeto. Para isto, pontos regularmente espaçados são distribuídos em torno da projeção horizontal da nuvem de pontos.

O seguinte passo consiste em detectar pontos notáveis dentro da nuvem de pontos. Para isto é construída uma triangulação de Delaunay. Com base na relação espacial entre os pontos, descrita pelas arestas da triangulação, a vizinhança em torno de cada ponto é identificada. As coordenadas dos pontos vizinhos e ponto central são então usadas para estimar a dispersão dos pontos neste local, calculando a matriz variância-covariância. Os autovalores e autovetores desta matriz são, a seguir calculados, e finalmente, um descritor de volume é calculado para a região. Neste caso foi usado o parâmetro de Curvatura, descrito na equação 5 (pág. 50). Aplicando um limiar de curvatura, a nuvem de pontos é separada em dois grupos: regiões planas e regiões com curvatura, que podem ser quinas ou bordas. O limiar a ser aplicado

depende muito da textura da nuvem de pontos. Caso a nuvem seja obtida de duas faixas diferentes e superpostas do levantamento LIDAR, a nuvem pode apresentar alta textura mesmo em regiões planas devido a falha no registro das nuvens. Por isto, especial cuidado deve ser dado à etapa de registro. No caso mais geral, o limiar usado fica perto da curvatura média.

### 3.4.2 Redução progressiva da densidade

O conjunto de pontos localizados em regiões planas é abundante e responsável por uma alta redundância nos dados. A análise de todos eles demanda alto esforço computacional e foi em parte evitada. Por este motivo, este conjunto foi progressivamente reduzido, gerando novas nuvens com menos pontos. Duas reduções foram aplicadas, reduzindo a densidade, selecionando um a cada cinco pontos (baixa densidade – 1) e um a cada dois pontos (densidade média – 2).

### 3.4.3 Algoritmos genéticos

A solução ótima ou sub-ótima do problema geométrico formulado, é obtida verificando se um conjunto dos pontos com alta curvatura pode ser usado para descrever os planos que contêm os pontos das regiões planas.

Como o custo computacional da análise de toda a nuvem inicial é alto, esta fase foi dividida em três etapas, variando a densidade da nuvem de pontos. A princípio é obtida uma aproximação da solução analisando a nuvem de baixa densidade ( $NP_1$ ). Neste caso, os algoritmos genéticos funcionam mais rápido, pois o cálculo da função de adequação analisa apenas um a cada cinco pontos das regiões planas. Porém, a solução obtida é uma boa aproximação da forma do telhado.

Na segunda etapa, a solução obtida com a nuvem de baixa densidade é incluída como uma parte da população inicial e a nuvem de densidade média ( $NP_2$ ) é analisada. Os algoritmos genéticos podem assim, aperfeiçoar a solução prévia, obtendo-se uma solução melhor, aquela que melhor aproxima a forma do objeto.

Finalmente, o conjunto de todos os pontos localizados nas regiões planas é analisado, desta vez incluindo a solução sub-ótima da análise da nuvem com densidade média.



### 3.5 AVALIAÇÃO

A avaliação foi feita a partir da observação da modelagem realizada. Deve-se observar: a identificação feita pelo AG dos vértices significativos e analisá-la a partir das coordenadas dos pontos encontrados; se houve o reconhecimento das bordas e dos planos de cada tipo de telhado e se houve dificuldade no encontro dos mesmos; a influência de ruídos e da densidade da nuvem de pontos, comparando as coordenadas dos pontos encontrados pelo algoritmo e as coordenadas determinadas como corretas; a distância entre linhas (scans) referentes aos dados reais na modelagem; e o tempo de processamento.

## 4 APRESENTAÇÃO DOS RESULTADOS

No desenvolvimento do algoritmo, foi necessário determinar valores numéricos para alguns parâmetros genéticos como: o número de elementos (gene de uma cadeia genética); o número de indivíduos (quantidade de soluções a serem avaliadas); e o número de indivíduos que sobrevivem em uma geração; o número de mutantes em uma geração. Esses parâmetros são fundamentais na execução do algoritmo, pois fazem parte de seu desenvolvimento e podem influenciar nos resultados obtidos. Esses valores foram escolhidos arbitrariamente e são mostrados na Tabela 4.

TABELA 4 – PARÂMETROS GENÉTICOS.

<b>Parâmetro Genético</b>	<b>Valor</b>
número de elementos	12
número de indivíduos	30
número de indivíduos que sobrevivem em uma geração	10
número de mutantes em uma geração	8

FONTE: A autora (2018).


Uma vez desenvolvido o algoritmo, fez-se uma avaliação utilizando tanto dados simulados, aqueles gerados por computador, como também dados reais, obtidos por LIDAR. A nuvem de pontos simulada para esta finalidade, descreve uma situação quase ideal, sendo todos os pontos de um plano de telhado aproximadamente coplanares, contendo ruído simulado. Já a nuvem de pontos obtidas por LIDAR, apresenta a situação real, podem existir diversos ruídos e os pontos pertencentes aos planos do telhado também não são necessariamente coplanares.

### 4.1 NUENS DE PONTOS SIMULADAS

Para os experimentos realizados com nuvens de pontos simuladas, desenvolveu-se um algoritmo que fornece três modelos de telhados na forma de nuvem de pontos. Esses modelos foram nomeados da seguinte forma: Telhado 1 – duas águas; Telhado 2 – quatro águas; Telhado 3 – 8 águas. As Figuras 18, 19, e 20


mostram uma representação desses telhados simulados, destacando os pontos significativos de cada um.

FIGURA 18 - REPRESENTAÇÃO DO TELHADO 1 (DUAS ÁGUAS).




FONTE: A autora (2018).

FIGURA 19 - REPRESENTAÇÃO DO TELHADO 2 (QUATRO ÁGUAS).



FONTE: A autora (2018).


FIGURA 20 - REPRESENTAÇÃO DO TELHADO 3 (OITO ÁGUAS).



FONTE: A autora (2018).

Devido ao grande número de pontos que uma nuvem pode ter, foi desenvolvida uma estratégia que visa acelerar o processo de modelagem. Para isto, a densidade da nuvem de pontos é reduzida sistematicamente. Desta forma foi possível realizar experimentos com diferentes densidades de pontos, para as nuvens simuladas. Um exemplo de variação de densidade de pontos é mostrado na Figura 21.

FIGURA 21 - EXEMPLO DO PROCESSO DE REDUÇÃO DA DENSIDADE DE PONTOS.



FONTE: A autora (2018).

O algoritmo principal integra algumas sub-rotinas e realiza o processo de funcionamento dos AGs. Porém, para a otimização do processamento, é feita uma detecção de bordas. Assim, cria-se uma malha regular dentro da área de estudo e se busca o ponto mais próximo a cada ponto desta grade dentro do conjunto de pontos. E também inclui-se o indivíduo mais apto da solução anterior.

Para efetuar o cruzamento entre os indivíduos selecionados é usada a técnica de *cruzamento em um ponto* (descrito no item 2.3.3.4.1), tendo o ponto de corte escolhido como sendo a metade do cromossomo (entre os dois genes centrais). Já a sub-rotina que trata do operador genético de mutação escolhe um indivíduo e um cromossomo, de forma aleatória, e determina um valor arbitrário de mutação, modificando sua estrutura e consequentemente sua característica.

O algoritmo foi utilizado nas nuvens de pontos simuladas e reais, tendo assim, os experimentos e os resultados apresentados a seguir.

Os experimentos com os telhados simulados foram realizados variando a distância entre linhas (scans) e o nível de ruído. O ruído simulado se dá por uma variação estipulada nas coordenadas x e y de um ponto. A distância entre linhas se refere ao espaçamento longitudinal, na direção do voo, e a taxa de ruído é uma componente aleatória que é adicionada aos dados simulados, com variação máxima estipulada entre 5 a 25 cm. Maiores valores de ruído geram telhados pouco uniformes

e conseqüentemente falsas bordas. Com esse experimento também foi possível analisar a variação do valor da função de aptidão no processo iterativo.

#### 4.1.1 Experimento I: efeito do ruído

O primeiro experimento tem como finalidade avaliar o efeito que a taxa de ruído tem no resultado final. Para isto, diferentes nuvens de pontos referente ao modelo Telhado 1, de duas águas, foram geradas variando o nível de ruído nos dados, sendo o espaçamento entre linhas de 5m e a distância entre pontos no mesmo scan de 50cm. Os resultados serão mostrados a seguir. A Tabela 5 apresenta os valores determinados do ruído para cada teste.

TABELA 5 - VALORES DOS RUÍDOS DETERMINADOS PARA CADA EXPERIMENTO.

<b>Teste</b>	<b>Ruído em x (cm)</b>	<b>Ruído em y (cm)</b>
<b>A</b>	5	5
<b>B</b>	10	10
<b>C</b>	15	15
<b>D</b>	20	20
<b>E</b>	25	25

FONTE: A autora (2018).


Nas figuras a seguir, são mostrados os resultados de três etapas do primeiro experimento: com baixa (a), média (b) e alta (c) densidade de pontos internos. Os pontos internos, localizados em regiões planas estão representados na cor vermelha. Já os pontos representados em azul, são os pontos de bordas e quinas identificados através da análise de curvatura, e são os mesmos para as três etapas. Nota-se que, os pontos em azul na região central, são os pontos da cumeeira do telhado.

Na primeira etapa, a densidade da nuvem de pontos foi reduzida com um fator 1:5. Sendo assim, tem-se menos pontos internos e o processo evolui mais rapidamente. Ao lado direito da representação da densidade da nuvem de pontos, é apresentado um gráfico que mostra a evolução do “fitness”, ou adequação da solução.

A Figura 22.a, referente ao Teste A, mostra as etapas citadas anteriormente. Nota-se que nas primeiras iterações ocorrem grandes alterações nos valores de adequação (de aproximadamente 0,89 a 0,98) e que depois de 100 iterações a melhora é muito menor, tendendo a uma situação estável. Na Figura 22.b, é mostrado

o processo efetuado na segunda etapa, usando a densidade média que adota um ponto a cada dois e usa a melhor solução da primeira etapa. Fica claro que a primeira aproximação contribui muito para esta etapa. As mudanças no valor da adequação não são muito grandes, de aproximadamente 0,9983 a 0,9998. Uma terceira etapa foi executada, mas como não apresentou mudanças significativas, não foi incluída na análise.


FIGURA 22 - EVOLUÇÃO DAS ITERAÇÕES PARA A MODELAGEM DO TELHADO 1, COM ESPAÇAMENTO DE 5M E NÍVEL DE RUÍDO DE 5CM.



FONTE: A autora (2018).

Na Figura 23 é mostrado o resultado da modelagem obtido neste primeiro experimento. O modelo da forma do telhado coincide com o idealmente proposto. As dimensões do telhado estão corretas e sua forma é coerente.

FIGURA 23 - MODELAGEM FINAL DO TESTE A.



FONTE: A autora (2018).

Com a finalidade de avaliar quantitativamente o resultado, os pontos notáveis ou significativos, obtidos pelo algoritmo, foram comparados com aqueles originalmente utilizados para gerar a nuvem de pontos. O resultado desta comparação é apresentado na Tabela 6.

TABELA 6 - COMPARAÇÃO ENTRE OS PONTOS SIGNIFICATIVOS OBTIDO PELO ALGORITMO E OS ORIGINAIS.

<b>Teste A</b>										
<b>Ponto</b>	<b>Coordenada Teórica (m)</b>			<b>Coordenada AGs (m)</b>			<b>Discrepância (cm)</b>			<b>Resultante (cm)</b>
	$x_o$	$y_o$	$z_o$	$x$	$y$	$z$	$\Delta x$	$\Delta y$	$\Delta z$	$D$
<i>P1</i>	0,02	29,53	0,24	0,51	29,55	0,21	48,6	2,0	-3,0	48,7
<i>P2</i>	0,03	15,00	9,87	0,03	15,00	9,87	0,0	0,0	0,0	0,0
<i>P3</i>	0,01	0,05	0,04	0,01	0,05	0,04	0,0	0,0	0,0	0,0
<i>P4</i>	49,51	0,04	0,04	49,03	0,01	0,03	-48,0	-3,0	-1,2	48,1
<i>P5</i>	49,51	15,02	9,90	49,52	14,51	9,67	1,0	-51,0	-23,3	56,1
<i>P6</i>	49,52	29,54	0,22	49,52	29,02	0,55	0,0	-52,0	33,4	61,8
<i>Média (cm)</i>							0,3	-17,3	1,0	35,8
<i>RMS (cm)</i>							27,9	29,8	16,7	44,1

FONTE: A autora (2018).

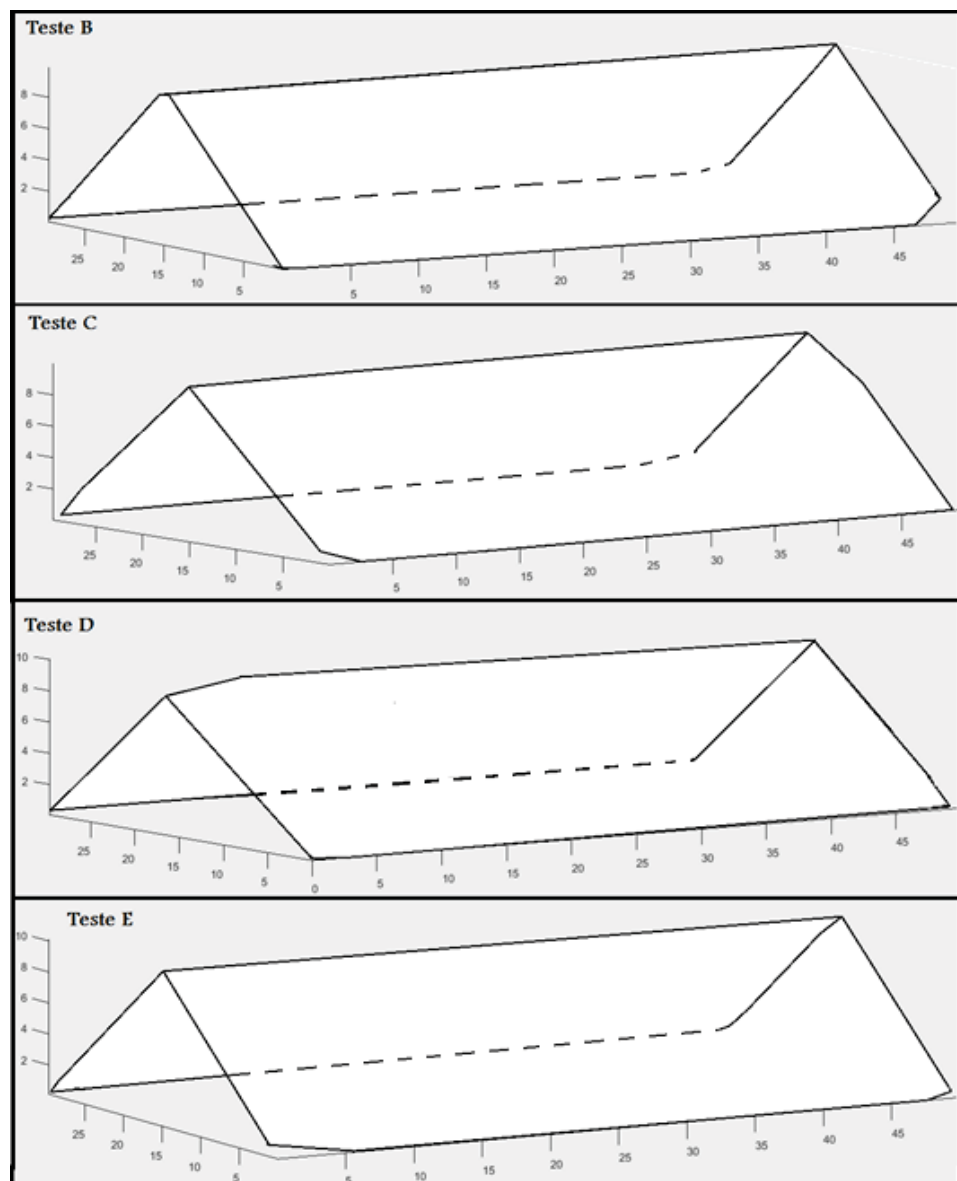
O mesmo procedimento foi repetido, alterando a variação da cota por introdução de ruído aleatório com máximo de 5, 10, 15, 20 e 25 cm. Variações acima de 25 cm não foram consideradas pois a acurácia em distância do sistema LIDAR aerotransportado aproxima-se dos 15 cm na prática. Os resultados numéricos para as modelagens dos Testes A a E estão apresentados na Tabela 7, e os modelos resultantes são mostrados na Figura 24.

TABELA 7 - RESULTADOS NUMÉRICOS OBTIDOS DOS TESTES DE A A E.

Ruído (cm)	Discrepância média (cm)			Resultante (cm)	RMS (cm)			RMS total (cm)
	x	y	z		x	y	z	
5	0,3	-17,3	1,0	35,8	27,9	29,8	16,7	44,1
10	1,4	6,6	29,9	67,7	2,6	92,3	58,9	109,5
15	1,9	-2,2	17,8	56,0	32,5	54,0	35,0	72,1
20	-14,8	22,0	-11,8	39,8	25,7	60,2	39,8	76,6
25	-0,2	13,6	17,6	51,3	4,9	55,1	37,9	67,1

FONTE: A autora (2018).

FIGURA 24 - MODELAGEM FINAL DOS TESTES B A E.



FONTE: A autora (2018).



Observando os modelos obtidos, pode-se dizer que não existe grande diferença entre eles e que o método proposto modela adequadamente a forma do telhado. Diferenças são observadas nas quinas do telhado, e ocorrem devido ao processo de modelagem falha ao identificar o ponto ótimo, porém escolhe um próximo, que fornece também uma boa solução. Os erros encontrados estão abaixo da equidistância entre linhas de varredura, que é de 5m.


Nota-se, porém, que o tamanho desta diferença não é grande, como é visto na Tabela 7. O RMS fica, em geral, abaixo de 1m, exceto no caso do Teste B (com 10cm de ruído). Também é observado que, de maneira geral, as diferenças médias aumentam com o nível de ruído, fato já esperado. Porém, a resultante, que representa a adição vetorial das três componentes, fica em torno de 50cm em média. Isto mostra que o método proposto é capaz de processar dados com certo nível de ruído, mas que melhores resultados podem ser esperados quando o ruído é menor.

#### 4.1.2 Experimento II: efeito da densidade de pontos

O experimento II foi realizado utilizando um telhado mais complexo, com quatro águas (Telhado 2), porém agora, variando a distância original entre linhas de varredura. No primeiro caso usou-se uma varredura com equidistância de 3m e no segundo de 5m.

A Figura 25 mostra a evolução registrada nas três etapas do processo. Novamente se nota a tendência comum da adequação da solução crescer significativamente nas primeiras iterações e tender a uma situação estável com o avanço do processo iterativo. Neste caso, diferentemente do anterior, houve uma pequena mudança na terceira fase, quando todos os pontos da nuvem são analisados (densidade maior).

FIGURA 25 - EVOLUÇÃO DAS ITERAÇÕES PARA A MODELAGEM DO TELHADO 2, COM ESPAÇAMENTO DE 3M E NÍVEL DE RUÍDO DE 5CM.



FONTE: A autora (2018).


A Tabela 8 apresenta os resultados da comparação da posição dos pontos significativos em relação aos pontos ideais, considerando distância entre linhas de varredura (scans) de 3 e 5 metros para o Telhado 2. E a Figura 26 mostra a modelagem final dos experimentos realizados com o Telhado 2.

TABELA 8 - RESUMO DA ANÁLISE DO ERRO VARIANDO A DISTÂNCIA ENTRE LINHAS REFERENTE AOS EXPERIMENTOS COM O TELHADO2.

Espaçamento (m)	Discrepância média (cm)			Resultante (cm)	RMS (cm)			RMS total (cm)
	x	y	z		x	y	z	
3	-10,0	5,8	-1,0	24,2	30,6	13,9	10,8	35,3
5	-0,3	10,4	-0,2	10,4	20,0	28,4	8,1	35,7

FONTE: A autora (2018).

FIGURA 26 - MODELAGEM FINAL DO TELHADO 2 CONSIDERANDO DIFERENTES ESPAÇAMENTOS ENTRE LINHAS: 3m E 5m.



FONTE: A autora (2018).


Observando os modelos obtidos, pode-se dizer que não existe grande diferença entre eles e que o método proposto modela adequadamente a forma do telhado tipo 2. Pode-se observar pequenas diferenças nas quinas do telhado, que também ocorrem devido ao processo de modelagem falhar ao identificar o ponto ótimo, porém também escolhe um próximo, que fornece uma boa solução. Os erros também são pequenos e abaixo da equidistância entre linhas de varredura, que é de 3m e 5m, como é visto na Tabela 7. O RMS fica, em geral, abaixo de 40cm.

Nota-se também que a resultante, que representa a adição vetorial das três componentes, fica em torno de 18cm em média. Isto mostra que o método proposto é capaz de processar dados com baixo nível de ruído e diferente densidade de pontos, mas que melhores resultados podem ser esperados quando a densidade é maior, porém isso implica num tempo maior de processamento. Os resultados obtidos tiveram qualidade satisfatória, tanto numericamente como visualmente. Verificou-se que os valores obtidos se encontram dentro do esperado e foram modelados a quantidade de faces planas esperadas com a geometria correta.

O experimento foi repetido novamente, agora, com um telhado ainda mais complexo, Telhado 3, com ruído de 5cm. Devido ao aumento da complexidade da forma do telhado, existe a necessidade de um número maior de pontos a serem encontrados, por isso a cadeia genética deve ter mais indivíduos. Nota-se, na Figura 27, que a detecção de bordas e quinas é eficiente e detecta muitos pontos candidatos a pontos significativos, descartando grande parte dos pontos por ficarem em regiões planas.

Novamente, a adequação mostra uma maior variação na primeira iteração (de aproximadamente 0,77 a 0,95) quando comparada a segunda (de aproximadamente 0,997 a 0,998), e se comporta de maneira similar àquela observada nos experimentos anteriores.


FIGURA 27 - EVOLUÇÃO DAS ITERAÇÕES PARA A MODELAGEM DO TELHADO 3, COM ESPAÇAMENTO ENTRE LINHAS DE 3m E RUÍDO DE 5cm.



FONTE: A autora (2018).

Já a Figura 28 mostra os modelos obtidos no final de cada etapa do processo. Pode ser observado que a solução obtida após a primeira etapa é bastante boa, tem sua forma próxima ao ideal, e que a mesma vai sendo melhorada nas seguintes etapas.

FIGURA 28 - EVOLUÇÃO DA MODELAGEM DE ACORDO COM AS ITERAÇÕES REFERENTES AO TELHADO 3 (ESPAÇAMENTO ENTRE LINHAS DE 3m E RUÍDO 5cm).



FONTE: A autora (2018).


Os dados referentes à avaliação quantitativa do resultado são mostrados na Tabela 9. Novamente observa-se pouca diferença entre os resultados obtidos com diferentes espaçamentos. Já a Figura 29 apresenta a modelagem final dos dois experimentos referentes ao Telhado 3.

TABELA 9 - RESUMO DA ANÁLISE DO ERRO VARIANDO A DISTÂNCIA ENTRE LINHAS REFERENTE AOS EXPERIMENTOS COM O TELHADO 3.

Espaçamento (m)	Discrepância média (cm)			Resultante (cm)	RMS (cm)			RMS total (cm)
	x	y	z		x	y	z	
3	-2,3	1,8	0,3	13,6	15,0	21,2	3,9	26,3
5	11,5	1,8	3,6	17,6	32,7	28,9	26,7	51,2

FONTE: A autora (2018).

FIGURA 29 – MODELAGEM FINAL DO TELHADO 3 COM ESPAÇAMENTOS ENTRE LINHAS DE 3m E 5m.



FONTE: A autora (2018).

Os resultados obtidos nestes dois casos apontam que as discrepâncias são baixas e dentro do esperado, o que leva a concluir que a diferença entre as linhas não introduz significativa alteração no produto. Entretanto, deve-se levar em consideração que estas nuvens de pontos foram geradas paralelas aos lados dos telhados e por isso podem descrever melhor a forma do telhado. Porém, em casos reais, as linhas de varredura quase nunca são paralelas aos lados do telhado. Por isso, se a distância entre linhas for muito grande, as quinas e bordas do telhado podem não ser corretamente registradas na varredura, o que ocasionaria falhas na representação do modelo.

Portanto, pode-se concluir que os pontos determinados como significativos pelo algoritmo, encontram-se dentro da resolução da nuvem. Já observando a modelagem, verifica-se que o telhado foi modelado de forma satisfatória, obteve-se a geometria correta e quantidade de faces planas esperada, neste caso, oito. Nota-se também que o ponto central superior difere de um teste para outro, havendo um deslocamento do ponto encontrado pelo algoritmo.


## 4.2 NUVENS DE PONTOS REAIS (LIDAR)

Realizou-se também, experimentos com dados reais, selecionando telhados de uma nuvem obtida por LIDAR, apresentada no item 4.2.1 deste trabalho. A nuvem de pontos foi pré-processada no software LasTools, para que assim fosse possível separar somente os telhados de interesse. Como exemplo, foram selecionadas cinco nuvens de pontos, referentes a telhados, com diferentes complexidades, para a apresentação dos resultados. Essas nuvens foram denominadas de: Telhado Casa 1; Telhado Casa 2; Telhado Casa 3; Telhado Casa 4; Telhado Casa 5. O processo de modelagem é o mesmo dos experimentos realizados com dados simulados.

### 4.2.1 Área de estudo

Para a realização dos experimentos foi utilizada uma nuvem de pontos obtida com LIDAR de uma área referente à cidade de Recife. Essa nuvem foi dividida em duas devido a quantidade de dados e informações. A partir dessas duas nuvens, foram escolhidos cinco telhados com diferentes complexidades para a apresentação dos resultados. As Figuras 30 e 31 mostram essas duas áreas.


FIGURA 30 - PRIMEIRA ÁREA REFERENTE À CIDADE DE RECIFE PARA A REALIZAÇÃO DOS EXPERIMENTOS.



FONTE: A autora (2018).



FIGURA 31 - SEGUNDA ÁREA REFERENTE À CIDADE DE RECIFE PARA A REALIZAÇÃO DOS EXPERIMENTOS.




FONTE: A autora (2018).

#### 4.2.2 Telhado Casa 1

O primeiro telhado escolhido tem características próximas ao telhado de quatro águas do experimento com dados simulados. É um telhado simples, com quatro planos, porém, nota-se que a distribuição das linhas não é uniforme e que provavelmente, neste caso, é o produto de duas ou mais varreduras. A Figura 32 apresenta a nuvem de pontos original do teste Telhado Casa 1. Sabe-se que o espaçamento entre pontos e entre linhas, é de aproximadamente 46cm e 1m respectivamente.


FIGURA 32 - NUVEM DE PONTOS ORIGINAL DO TELHADO CASA 1.



FONTE: A autora (2018).

Já a Figura 33 é mostra a evolução do processo iterativo nas três etapas do processo.

FIGURA 33 - EVOLUÇÃO DO CONJUNTO DE ITERAÇÕES PARA A MODELAGEM DO TELHADO CASA 1.



FONTE: A autora (2018).




No início da primeira etapa, processando a nuvem com menor densidade de pontos, é adotada uma distribuição regular de pontos como solução inicial e inserida como um indivíduo na proposta inicial da população. Esta solução regular inclui os pontos mais próximos das quinas do retângulo envolvente e alguns pontos no interior deste retângulo. Isto se justifica, pois, os telhados são geralmente formas regulares e retangulares. Com isso, os valores da adequação começam em torno de 0.78, o que já é considerado uma boa aproximação e reduz iterações iniciais. No final, a adequação atinge valores acima de 0.88, que faz com que o modelo seja considerado uma aproximação melhor do telhado. Para esta etapa, a função objetivo é linear (eq. 20, pág.55).

Na segunda etapa, a melhor solução do passo anterior é inserida como um indivíduo, e então é analisado o conjunto de pontos internos com densidade média e a função objetivo. Por se tratar de um novo conjunto de pontos, o valor do “*fitness*” nesta etapa é diferente do valor final da etapa anterior, mesmo usando a melhor solução previamente obtida. Nota-se, na Figura 32, que a adequação (*fitness*) novamente cresce, porém, o crescimento já não é tão grande, quando comparado com a etapa anterior (de aproximadamente 0,9836 a 0,9852).

Já na terceira etapa, todos os pontos internos são utilizados, incluindo a solução da segunda etapa no conjunto de indivíduos. Neste caso, a função objetivo é do tipo quadrática (equação 7), pois esta confere maior peso a maiores diferenças, permitindo um ajuste mais fino. O processo iterativo mostra uma melhora progressiva, mas a variação não é grande (0,9835 a 0,985). Entretanto, esta fase é importante para corrigir erros resultantes da fase anterior.

Na Figura 34 estão os resultados de cada fase citada. É visível que a primeira fase já produz uma boa aproximação do telhado, sendo que pequenas correções são incluídas nas fases seguintes.


FIGURA 34 - EVOLUÇÃO DA MODELAGEM DE ACORDO COM AS ITERAÇÕES REFERENTES AO TELHADO CASA 1.



FONTE: A autora (2018).

A princípio não se conhece o número total de pontos ou triângulos necessários para descrever o telhado, portanto, uma quantidade grande de pontos é usada na modelagem, o que pode gerar triângulos redundantes. Estes triângulos redundantes foram eliminados analisando o ângulo entre triângulos adjacentes. As arestas com ângulos pequenos (menores que 45 graus) são eliminadas. Por exemplo, na Figura 35 é mostrada a solução final deste experimento (35.a) e a solução após a remoção de arestas com ângulos menores que 45 graus (35.b).

FIGURA 35 - MODELAGEM FINAL DO TELHADO CASA 1 E SEU RESULTADO APÓS A REMOÇÃO DE ARESTAS COM ÂNGULOS MENORES DE QUE 45 GRAUS.



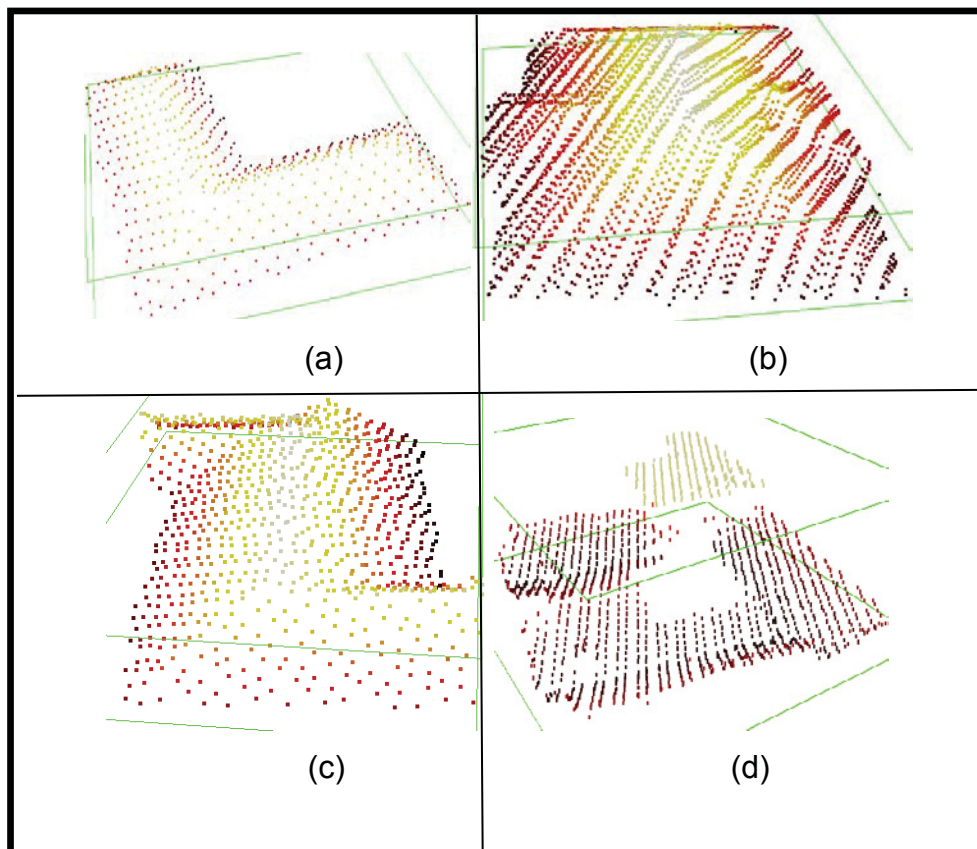
FONTE: A autora (2018).

#### 4.2.3 Telhado Casa 2/ Casa 3/ Casa 4/ Casa 5

A Figura 36 apresenta as nuvens de pontos originais para quatro outros telhados retirados de uma varredura LIDAR da cidade de Recife. Estas nuvens foram processadas usando o método proposto e serão brevemente discutidas a seguir.

As Figuras 36.a e 36.c mostram o Telhado Casa 2 e Casa 4, que tem os formatos de “L” e “Z” respectivamente. O Telhado Casa 3, apresentado na Figura 36.b, é retangular, de quatro águas e com duas saliências nas duas maiores superfícies, o que introduz um maior grau de dificuldade na modelagem. Já a Figura 36.d, mostra o Telhado Casa 5, que é a cobertura de um prédio (provavelmente terraço), com um telhado horizontal e um segundo telhado menor, plano, correspondente à caixa de água. Este último exemplo foi incluído com o intuito de verificar se o método é capaz de detectar telhados planos. Sabe-se que o espaçamento entre pontos e entre linhas, é de aproximadamente 45cm e 1m respectivamente.

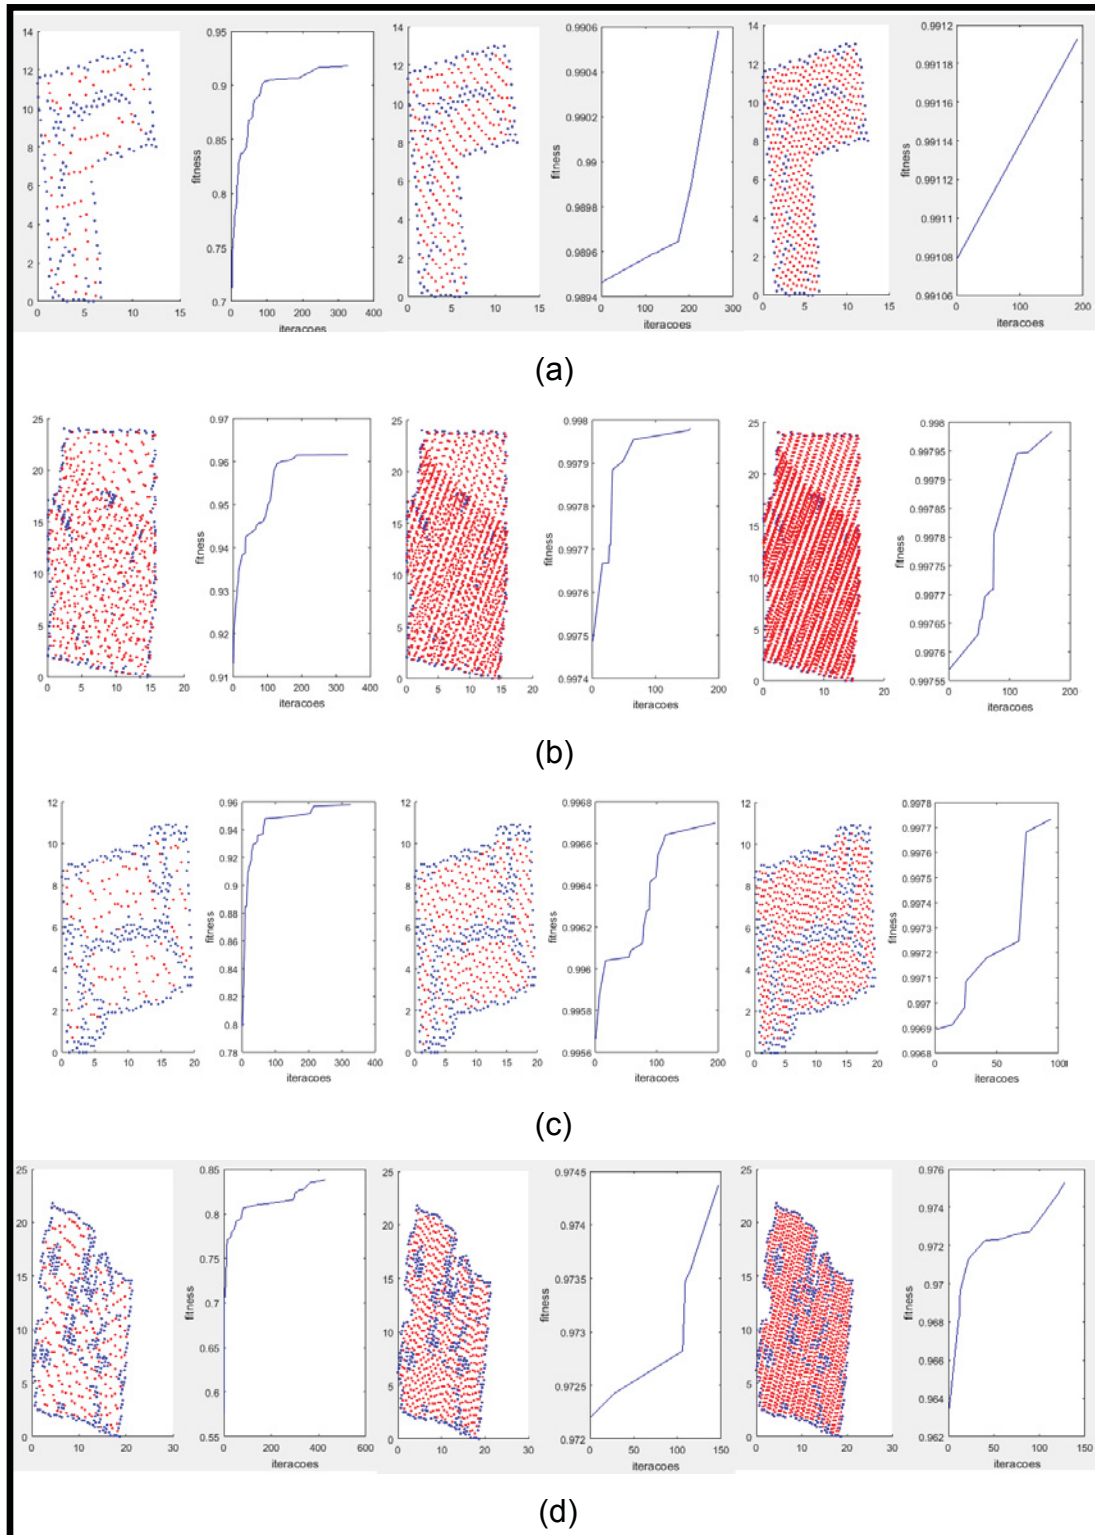
FIGURA 36 - NUVENS DE PONTOS ORIGINAIS DOS TELHADOS (A) CASA 2, (B) CASA 3, (C) CASA 4 E (D) CASA 5.



FONTE: A autora (2018).

A evolução dos valores do *fitness*, ou adequação, em cada etapa do processo, são apresentadas na Figura 37.

FIGURA 37 - EVOLUÇÃO DO CONJUNTO DE ITERAÇÕES PARA A MODELAGEM DOS TELHADOS: (A) CASA 2, (B) CASA 3, (C) CASA 4 E (D) CASA 5.

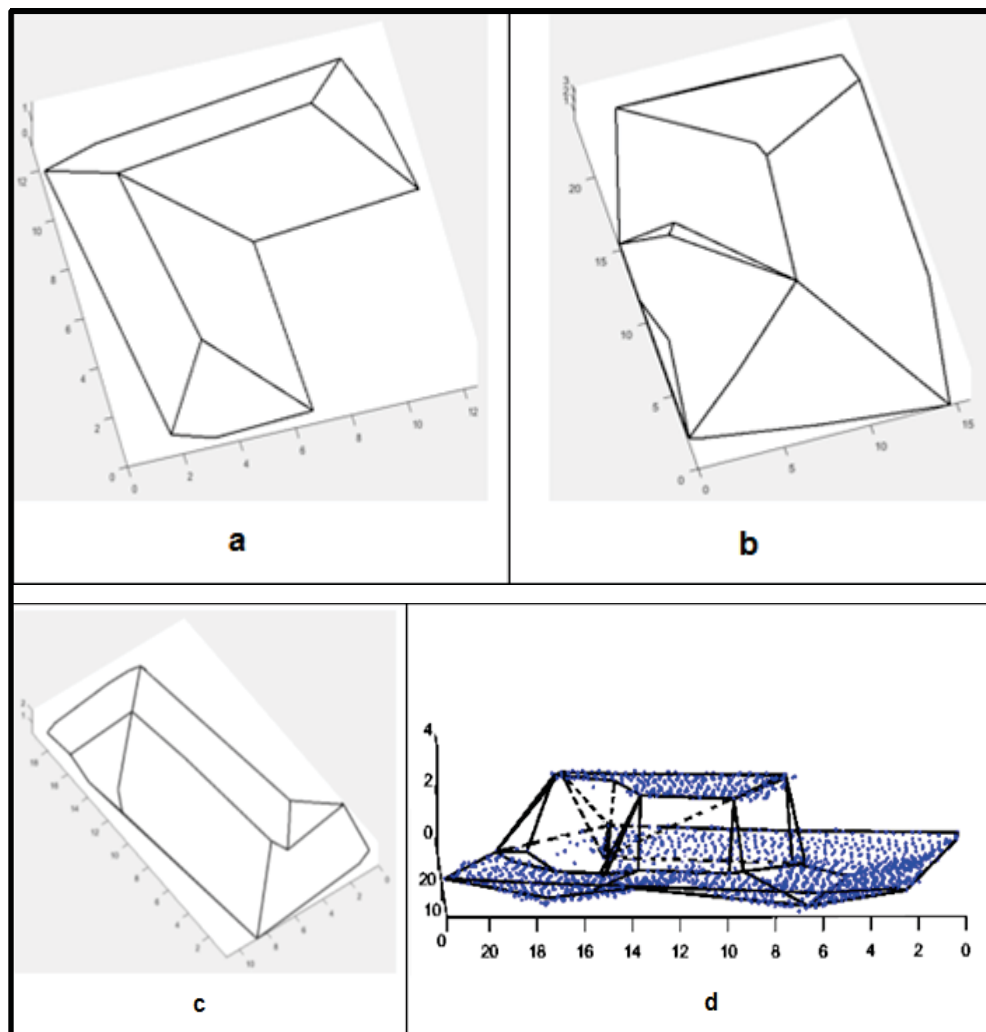


FONTE: A autora (2018).

Nota-se aqui, uma tendência geral similar entre a evolução da adequação nos quatro casos, onde o maior crescimento da adequação ocorre na primeira etapa. Portanto, o algoritmo funciona eficientemente com uma nuvem de pontos reduzida, desde que todas as faces do telhado tenham pontos internos. O processo de detecção de quinas e bordas é eficiente, pois os pontos candidatos a pontos notáveis são suficientemente detectados. Na segunda e terceira iteração, a evolução da adequação é menor e mais lenta.

Na Figura 38 são mostrados os resultados finais destes experimentos, as modelagens realizadas. É feita inicialmente uma análise qualitativa, comentando as características dos modelos obtidos, logo depois é feita uma análise quantitativa dos resultados.

FIGURA 38 - MODELAGEM FINAL DOS TELHADOS (A) CASA 2, (B) CASA 3, (C) CASA 4 E (D) CASA 5.



FONTE: A autora (2018).

O Telhado Casa 2 foi bem modelado. Nota-se que o telhado é composto por seis planos e suas interseções foram bem detectadas. Observa-se também que as bordas do telhado não foram caracterizadas como retas. Isto é inerente aos dados, ao padrão de varredura, e não depende do método proposto.

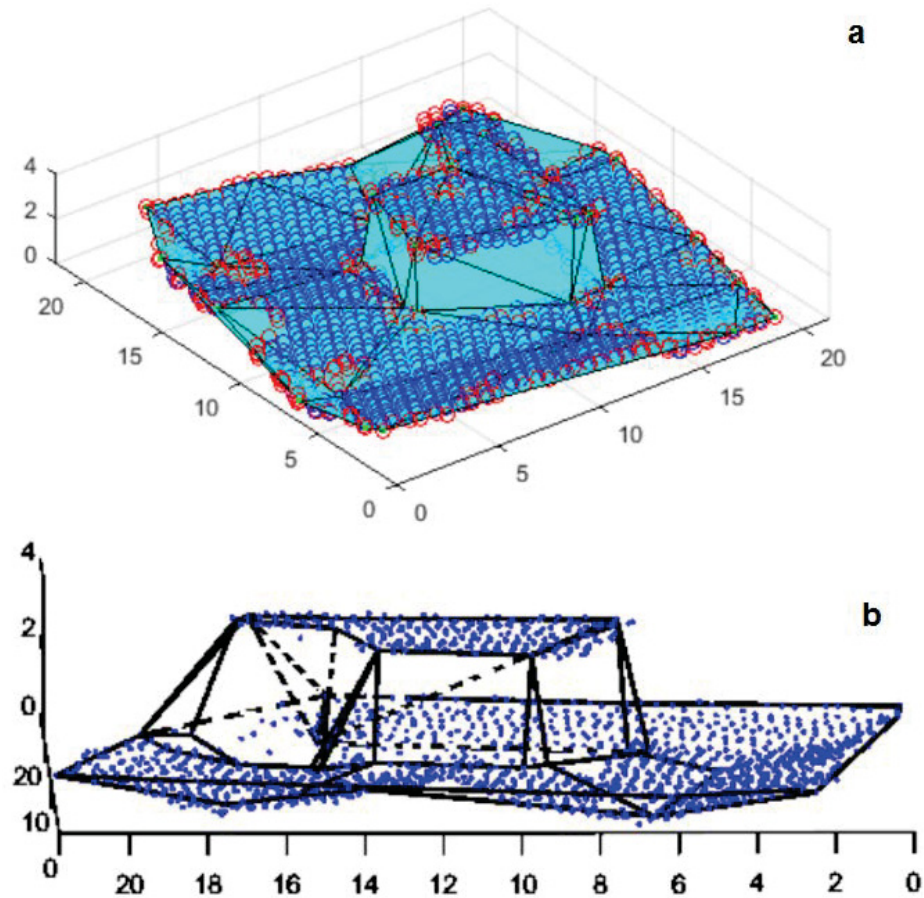
O segundo caso (Telhado Casa 3), por ser mais complexo, não produziu resultados totalmente corretos. A forma geral do telhado foi modelada, mas o método proposto falhou em detectar os detalhes presentes nas superfícies maiores. Neste caso, as duas saliências nas laterais não foram modeladas, pois não são elevadas significativamente em relação ao telhado. Sendo assim, elas foram incluídas no mesmo plano. Porém, parte desse detalhe foi detectado no lado esquerdo, como mostra a Figura 38.b.

O terceiro caso (Telhado Casa 4) foi bem modelado. Na parte superior da Figura 38.c, nota-se que a forma do telhado foi bem modelada, diferentemente do que observa na parte inferior da figura, pois é possível verificar que a cumeeira do telhado apresenta dois pontos centrais ao invés de um. Isto pode ser um indicativo de que seriam necessárias mais iterações na terceira etapa. De fato, observando a Figura 37.c, observa-se que a adequação cresce na terceira etapa, mas não atinge um máximo formando um *plateau*.

Já o telhado horizontal, apresentado no Figura 38.d, pode-se dizer que obteve um resultado satisfatório, pois foram identificados os planos. Entretanto, pode-se concluir que o processo de identificação no plano inferior deve ser melhor desenvolvido. Um problema possível aqui é que não existem pontos que representem as paredes da caixa de água, o que pode limitar a eficiência do método, como é mostrado na Figura 39. A Figura 39a e 39b mostram visões diferentes da identificação dos planos do Telhado 5, uma apresenta a visão lateral (b) e outra uma visão inclinada, entre superior e lateral (a).



FIGURA 39 - PONTOS DE BORDAS (VERMELHO) E INTERNOS (AZUL) SUPERPOSTOS A TRIANGULAÇÃO DO PRIMEIRO RESULTADO PARCIAL.



FONTE: A autora (2018).

Com a finalidade de avaliar se as quinas e pontos notáveis do telhado encontrados pelo método estão próximos dos pontos considerados corretos, foi feita uma comparação entre os pontos detectados pelo algoritmo e pontos selecionados manualmente. Cada nuvem foi analisada visualmente e foram selecionados os pontos que melhor descrevem o telhado em questão. Este conjunto foi usado como referência. Na Tabela 10 é apresentado um resumo desta comparação. O Telhado Casa 5 não foi incluído.

TABELA 10 - RESUMO DA ANÁLISE DO ERRO VARIANDO NOS EXPERIMENTOS COM O TELHADO CASA 1 A 4 .

Telhado	Espaçamento (cm)	Discrepância média (cm)			Resultante (cm)	RMS (cm)			RMS total (cm)
		x	y	z		x	y	z	
Casa 1	100	2,0	-5,0	-1,4	10,1	10,7	13,4	1,3	17,2
Casa 2	96	-6,7	-6,7	-6,8	11,6	28,3	28,3	26,9	48,2
Casa 3	100	-5,7	0,0	0,0	5,7	9,8	0,0	0,0	9,8
Casa 4	92	-4,5	-6,4	1,5	8,3	14,1	20,4	8,8	26,4

FONTE: A autora (2018).

Os erros encontrados não são grandes quando comparados com a distância entre linhas de varredura. O valor dos erros, em média, é próximo à distância entre pontos ao longo de uma mesma linha, que em média varia de 45 a 47 cm. Isto significa que a solução encontrou um ponto vizinho àquele considerado adequado visualmente. Embora esta análise seja quantitativa, deve-se ressaltar que mesmo os pontos de referência são difíceis de se encontrar visualmente.



## 5 CONSIDERAÇÕES FINAIS

A presente pesquisa teve como objetivo modelar telhados de faces planas a partir de nuvens de pontos simulada e obtida com LIDAR, utilizando algoritmos genéticos. Para isso foi desenvolvido um método de detecção de bordas e quinas para nuvens de pontos de telhados, implementou-se rotinas em MatLab para a composição do AG, e foi proposta uma função objetivo para o problema de modelagem. Com os resultados obtidos foi possível avaliar o método com dados simulados e dados reais, assim como o efeito da densidade de pontos na busca da solução ótima. Se tratando das nuvens de pontos simuladas, foram realizados nove testes, com três tipos de telhados diferentes. Já em relação aos dados reais, foram realizados experimentos com diferentes nuvens de pontos obtidas por LIDAR, pré-processadas. Neste trabalho foram apresentados cinco exemplos com geometrias diferentes.

Pode-se observar que as resultantes das discrepâncias (entre as coordenadas dos pontos significativos reais e as encontradas pelo algoritmo) obtidas, para ruídos (variação nas coordenadas x e y) simulados de 5, 10, 15, 20 e 25 cm, se encontram entre 35,8 cm e 67,7 cm. E o RMS total em cada experimento varia de 44,1 cm a 109,5 cm. Diferenças são observadas nas quinas do telhado, e ocorrem devido ao processo de modelagem falha ao identificar o ponto ótimo, porém o algoritmo escolhe um próximo, que fornece também uma boa solução. Os erros encontrados estão abaixo da equidistância entre linhas de varredura, que é de 5m. Os resultados comprovam que o método proposto pode tratar dados com certo nível de ruído. Se a amplitude do ruído for de até 25cm, o método funciona. Quando o ruído é maior, falsas bordas e quinas são encontradas. Neste caso não vale a pena detectar bordas.

Quando se trata do experimento referente ao efeito da densidade de pontos, verifica-se que, para o Telhado 2 (com quatro águas) e variando a distância original entre linhas de varredura em 3m e 5m, as resultantes das discrepâncias são de 24,2 cm e 10,4 cm respectivamente. E o RMS total em cada experimento é de 35,3 cm e 35,7 cm respectivamente. Assim, mesmo observando pequenas diferenças nas quinas do telhado, que ocorrem devido ao processo de modelagem falhar ao identificar o ponto ótimo, pode-se dizer que não existe diferença significativa entre eles e que o método proposto modela adequadamente a forma do Telhado 2.

Já para o Telhado 3 (com oito águas) e também variando a distância original entre linhas de varredura em 3m e 5m, as resultantes das discrepâncias são de 13,6

cm e 17,6 cm respectivamente. E o RMS total em cada experimento é de 26,3 cm e 51,2 cm respectivamente. Portanto, os erros se encontram abaixo da equidistância entre linhas de varredura, que é de 3m e 5m. Isto significa que o método proposto é capaz de processar dados com diferentes densidades de pontos, porém melhores resultados podem ser esperados quando a densidade é maior, entretanto isso implica num tempo de processamento maior.

Nestes experimentos os resultados obtidos tiveram qualidade satisfatória, tanto numericamente como visualmente. As discrepâncias entre as coordenadas reais e as encontradas pelo algoritmo, são baixas e dentro do esperado, o que leva a concluir que a discrepância entre as linhas não introduz significativa alteração no produto. Portanto, os valores obtidos se encontram dentro do esperado e foram modelados a quantidade de faces planas esperadas com a geometria correta.

Quando se trata dos experimentos realizados com dados reais, obtidos por LIDAR, sabe-se que foram escolhidos cinco telhados com diferentes complexidades para a apresentação dos resultados. O quinto telhado escolhido possui forma plana, horizontal, portanto se diferencia dos outros, assim não foram obtidos resultados numéricos para este caso. Foi possível verificar que as resultantes das discrepâncias obtidas, para os quatro primeiros telhados, possuem os valores de 10,1 cm, 11,6 cm, 5,7 cm e 8,3 cm respectivamente. Já o RMS total em cada experimento é de 17,2 cm, 48,2 cm, 9,8 cm e 26,4 cm respectivamente. Os erros encontrados não são significativos quando comparados à distância entre linhas de varredura de cada telhado. O valor dos erros, em média, é próximo à distância entre pontos ao longo de uma mesma linha, que em média varia de 45 a 47 cm, o que significa que o algoritmo encontrou um ponto vizinho àquele considerado adequado visualmente. Mesmo esta análise sendo quantitativa, deve-se ressaltar que mesmo os pontos de referência são difíceis de se encontrar visualmente.

Já sobre o telhado horizontal, pode-se dizer o resultado obtido foi satisfatório, já que os planos foram identificados. Entretanto, o processo de identificação no plano inferior deve ser melhor desenvolvido. Um problema possível, que pode limitar a eficiência do método, é que não existem pontos que representem as paredes da caixa de água.

Conclui-se então que, método pode ainda ser usado, desde que se considere como candidatos a pontos notáveis todos os pontos da nuvem. Isto elevaria significativamente o tempo de processamento. O método também não é afetado

significativamente pela variação de distância entre linhas de varredura, desde que os planos dos telhados contenham pontos suficientes. Outra constatação é que o método funciona bem mesmo quando a quantidade de pontos é reduzida. O uso dos algoritmos genéticos permite a modelagem de telhados com formas genéricas. Porém, depende da detecção adequada de quinas e bordas.

A proposta de dividir o processo em três etapas mostrou redução no tempo de processamento. Em todas as etapas, o método dos algoritmos genéticos converge para uma solução bem próxima da forma real do telhado. Quando aplicado a dados reais, o método também produz bons resultados, principalmente com edificações de telhados de faces planas. A presença de detalhes no telhado pode afetar o desempenho do método, que por sua vez, não permite modelar detalhes sejam significativos. As linhas obtidas, que definem o telhado, devem ainda ser tratadas, buscando adequá-las a restrições de paralelismo e ângulos retos, por exemplo. Isto não foi realizado nessa pesquisa, porém, pode ser feito em trabalhos futuros.

Em termos de coordenadas dos pontos notáveis, os resultados numéricos obtidos encontram-se dentro do esperado, e as modelagens encontradas apresentaram geometria coerente. As discrepâncias entre os pontos ideais e obtidos pelo algoritmo são pequenas e sem grande significância, e o tempo de processamento é rápido, o que otimiza o processo.

Desta forma, pode-se concluir que o método proposto é eficiente para a modelagem de telhados de faces planas. Como vantagem, pode-se destacar o fato de não haver a necessidade de uma definição prévia da forma do telhado, podendo haver geometrias irregulares, com saliências e diferente quantidade de águas. Outra vantagem a ser citada é o rápido tempo de processamento. Ou também, o fato de que não há a necessidade de informações auxiliares como mapas, imagens, dicionário de formas ou detecção de planos, somente a nuvem de pontos já é suficiente para a realização do processo. Pode ser destacado também o fato de que foi possível identificar um telhado de face plana única, porém é importante que haja um aprimoramento nesse caso especificamente.

## 5.1 RECOMENDAÇÕES PARA TRABALHOS FUTUROS

Para pesquisas posteriores, recomenda-se o aprimoramento do algoritmo para telhados horizontais, buscando soluções que permitam modelar as paredes dos elementos superpostos. Outro tópico que merece atenção é a otimização do processo de detecção de bordas para o refinamento da modelagem.

Sabe-se também que foi apenas considerada a curvatura, porém deve ser verificado se outros descritores da variação local da nuvem de pontos permitem uma melhor detecção de quinas e bordas. Recomenda-se também a pesquisa de outras possibilidades para a função objetivo que define a adequação dos indivíduos, assim como a variação dos parâmetros genéticos, para verificar se há influência significativa de algum parâmetro específico.

E por fim, neste trabalho, a função considera a distância média entre os pontos da nuvem original e o modelo do telhado, entretanto, o uso da média muitas vezes não permite encontrar pequenos detalhes na forma do objeto, e pode mascarar numericamente algum deslocamento de pontos significativo, portanto, recomenda-se verificar outro elemento que não a distância média entre os pontos da nuvem original e o modelo do telhado.

## REFERÊNCIAS

- AWRANGJEB, Mohammad; ZHANG, Chunsun; FRASER, Clive S. Automatic reconstruction of building roofs through effective integration of LiDAR and multispectral imagery. In: **XXII ISPRS Congress**. 2012.
- BOTELHO, M. F.; CENTENO, J. A. S. Reconstrução tridimensional de edificações utilizando dados laser scanner aerotransportados. **Boletim de Ciências Geodésicas**, v. 13, n. 1, 2007.
- CARVALHO, D. R. Árvore de decisão/ algoritmo genético para tratar o problema de pequenos disjuntos em classificação de dados. **Universidade Federal do Rio de Janeiro, Rio de Janeiro, Brazil. Doctor Thesis. 162pp**, 2005.
- CASTRO, L.N.; VON ZUBEN, F.J. Algoritmos Genéticos (AG's).
- CHENG, L., GONG, J., CHEN, X., & HAN, P. Building boundary extraction from high resolution imagery and lidar data. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 37, n. PART B3, p. 693-698, 2008.
- COX, E. **Fuzzy modeling and genetic algorithms for data mining and exploration**. Elsevier, 2005.
- DAL POZ, A. P.; HABIB, A. F.; MARCATO, V. J.; & CORREIA, L. D. S. Uso de dados fotogramétricos no refinamento geométrico de contornos de telhados de edifícios extraídos de dados LASER. **Boletim de Ciências Geodésicas**, v. 15, n. 4, 2009.
- DAL POZ, A. P. Filtragem de dados de varredura a laser: Princípios e exemplos. **XVI Simpósio Brasileiro de Sensoriamento Remoto**, p. 6057-6064, 2013.
- DALMOLIN, Q. **Sistema laserscanner: conceitos e princípios de funcionamento - Curitiba, UFPR**, 2003.
- DASH, J.; STEINLE, E.; SINGH, R. P.; & BAHR, H. P. Automatic building extraction from laser scanning data: an input tool for disaster management. **Advances in space research**, v. 33, n. 3, p. 317-322, 2004.
- DAWKINS, R. A escalada do Monte Improvável: uma defesa da teoria da evolução. São Paulo – SP: Companhia das Letras, 1996.
- DEMANTKÉ, J.; VALLET, B.; PAPARODITIS, N. Streamed vertical rectangle detection in terrestrial laser scans for facade database production. **IAPRS I-3**, p. 99-104, 2012.
- DOS SANTOS GALVANIN, E. A.; DAL POZ, A. P.; PIRES DE SOUZA, A. D. Extração automática de contornos de telhados usando dados de varredura a laser e Campos Randômicos de Markov. **Boletim de Ciências Geodésicas**, v. 14, n. 2, 2008.

ERCOLIN FILHO, L.; CENTENO, J. A. S.; MITISHITA, E. A.. Detecção automática de áreas planas em telhados de edificações utilizando nuvem de pontos LIDAR. **Revista Brasileira de Cartografia**, v. 68, n. 3, 2016.

FILIN, S.; PFEIFER, N. Neighborhood systems for airborne laser data. **Photogrammetric Engineering & Remote Sensing**, v. 71, n. 6, p. 743-755, 2005.

GEYER-SCHULTZ, A. Fuzzy rule-based expert systems and genetic machine learning. Heidelberg: Physica-Verlag, 1997.

GOLDBERG, D. E. Genetic algorithms in search, optimization & machine learning. [S.l.]: Addison-Wesley, 1989.

HAALA, N.; BRENNER, C.; ANDERS, K. 3D urban GIS from laser altimeter and 2D map data. **International Archives of Photogrammetry and Remote Sensing**, v. 32, p. 339-346, 1998.

HABIB, A. F.; KERSTING, A. P.; BANG, K. A point-based procedure for the quality control of LIDAR data. In: **6th International Symposium on Mobile Mapping Technology, Presidente Prudente, São Paulo, Brazil**. 2009.

HINTERDING, R., Representation, Mutation and Crossover Issues in Evolutionary Computation, In: **Proc. Conference on Evolutionary Computation**, pp 916-923, 2000.

JARZĄBEK-RYCHARD, M.; BORKOWSKI, A. 3D building reconstruction from ALS data using unambiguous decomposition into elementary structures. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 118, p. 1-12, 2016.

JOCHEM, A.; HOFLE, B.; WICHMANN, V.; RUTZINGER, M. & ZIPF, A. Area-wide roof plane segmentation in airborne LiDAR point clouds. **Computers, Environment and Urban Systems**, v. 36, n. 1, p. 54-64, 2012.

JUTZI, B.; GROSS, H. Nearest neighbour classification on laser point clouds to gain object structures from buildings. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 38, n. Part 1, p. 4-7, 2009.

KABOLIZADE, M.; EBADI, H.; MOHAMMADZADEH, A. Design and implementation of an algorithm for automatic 3D reconstruction of building models using genetic algorithm. **International Journal of Applied Earth Observation and Geoinformation**, v. 19, p. 104-114, 2012.

KADA, M.; MCKINLEY, L. 3D building reconstruction from LiDAR based on a cell decomposition approach. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 38, n. Part 3, p. W4, 2009.

KERSTING, J.; CENTENO, J.A.S.; MACHADO, A.; & PEDRO, P. Filtragem de modelos digitais de superfície derivados de varredura a LASER usando a triangulação de Delaunay. **Série em Ciências Geodésicas**, v. 5, p. 145-160, 2005.

KIM, K.; SHAN, J. Building roof modeling from airborne laser scanning data based on level set approach. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 4, p. 484-497, 2011.

LAFARGE, F.; DESCOMBES, X.; ZERUBIA, J.; & PIERROT-DESEILLIGNY, M. Structural approach for building reconstruction from a single DSM. **IEEE Transactions on pattern analysis and machine intelligence**, v. 32, n. 1, p. 135-147, 2010.

LARI, Z.; HABIB, A. Alternative methodologies for the estimation of local point density index: Moving towards adaptive LiDAR data processing. **Int. Arch. Photogramm. Remote Sens. Spat. Inform. Sci.**, v. 39, p. 127-132, 2012.

LEE, I.; SCHENK, T. Perceptual organization of 3D surface points. **International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences**, v. 34, n. 3/A, p. 193-198, 2002.

LI, Y.; WU, H.; AN, R.; XU, H.; HE, Q.; & XU, J. An improved building boundary extraction algorithm based on fusion of optical imagery and LiDAR data. **Optik-International Journal for Light and Electron Optics**, v. 124, n. 22, p. 5357-5362, 2013.

LINDEN, R. **Algoritmos genéticos: uma importante ferramenta da inteligência computacional**. Brasport, 2006.

LINSEN, L.; PRAUTZSCH, H. Local versus global triangulations. In: **Proceedings of EUROGRAPHICS**. 2001. p. 257-263.

LUCAS, D. C. Algoritmos genéticos: uma introdução. **Universidade Federal do Rio Grande do Sul-Porto Alegre**, 2002.

MAAS, Hans-Gerd; VOSSELMAN, George. Two algorithms for extracting building models from raw laser altimetry data. **ISPRS Journal of photogrammetry and remote sensing**, v. 54, n. 2-3, p. 153-163, 1999.

MACHADO, A. M. L.; MITISHITA, E. A. Detecção automática de contornos de edificações utilizando imagem gerada por câmara digital de pequeno formato e dados LIDAR. **Boletim de Ciências Geodésicas**, v. 12, n. 2, 2006.

MALLET, C.; BRETAR, F.; ROUX, M.; SOERGER, U.; & HEIPKE, C. Relevance assessment of full-waveform lidar data for urban area classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 6, p. S71-S84, 2011.

MARCATO, V.J.; DAL POZ, A. P. Refinamento geométrico de contornos e cumeeiras de telhados de edifícios extraídos de dados laser com uso de imagem aérea. **Boletim de Ciências Geodésicas**, v. 20, n. 3, 2014.



MARCATO, V. J. Extração de contornos de telhados de edifícios a partir da integração de imagem aérea de alta-resolução e dados LASER, utilizando campos aleatórios de Markov. 2016.

MENDES, T. S. G.; HERNANDES, A. N.; DAL POZ, A. P. Avaliação do uso de informação de textura dos dados laser na classificação de superfícies impermeáveis. **IV Simpósio Brasileiro de Geomática – SBG2017**. 2017.

MICHALEWICZ, Z. Evolutionary Programming and Genetic Programming. In: **Genetic Algorithms+ Data Structures= Evolution Programs**. Springer Berlin Heidelberg, 1996. p. 283-287.

MILIARESIS, G.; KOKKAS, N. Segmentation and object-based classification for the extraction of the building class from LIDAR DEMs. **Computers & Geosciences**, v. 33, n. 8, p. 1076-1087, 2007.

MITCHELL, M. Genetic Algorithms: An Overview. **Complexity**, v. 1, n. 1, p. 31-39, 1995.

MITCHELL, M. **An introduction to genetic algorithms**. MIT press, 1998.

MORO, R. C.; CENTENO, J. A. S. Filtragem e classificação de nuvem de pontos para a geração de nuvem de pontos. In: **III Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação**, Anais. Curitiba, 2010.

OLIVEIRA, G. R. K. Uso integrado de dados LiDAR e imagens aéreas aplicado na extração de contornos de telhados de edificações. 2016.

ORTHUBER, E.; AVBELJ, J. 3D building reconstruction from lidar point clouds by adaptive dual contouring. **ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 2, n. 3, p. 157, 2015.

PAPPA, G. L. Seleção de atributos utilizando Algoritmos Genéticos multiobjetivos. Curitiba. 85p. In: **Dissertação de Mestrado do Programa de Pós Graduação em Informática Aplicada da Pontifícia Universidade Católica do Paraná**. Curitiba, 2002.

PARK, J.; LEE, I.; & CHOI, Y.. Automatic extraction of large complex buildings using lidar data and digital maps. 2006.

POTJE, G. A.; PAZOTI, M. A.; SILVA, F. A. D.; PEREIRA, D. R.; ARTERO, A. O.; & PITERI, M. A. Extração de contorno de telhados de edificações utilizando dados laser e imagens aéreas. In: **Colloquium Exactarum**. 2014. p. 104-119.

POZO, A.; CAVALHEIRO, A. D. F.; ISHIDA, C.; SPINOSA, E.; & RODRIGUES, E. M. Computação evolutiva. **Universidade Federal do Paraná, 61p.(Grupo de Pesquisas em Computação Evolutiva, Departamento de Informática-Universidade Federal do Paraná)**, 2005.



ROTTENSTEINER, F.; BRIESE, C. **Automatic generation of building models from LIDAR data and the integration of aerial images**. 2003.

SCHIMALESKY, V.; CENTENO, J. A. S. Avaliação da qualidade da informação altimétrica derivada da varredura a laser em uma região coberta por vegetação: estudo de caso. **Floresta**, v. 38, n. 4, 2008.

SAMPATH, A.; SHAN, J. Segmentation and reconstruction of polyhedral building roofs from aerial lidar point clouds. **IEEE Transactions on geoscience and remote sensing**, v. 48, n. 3, p. 1554-1567, 2010.

SANTOS, J. S. Mineração de dados utilizando algoritmos genéticos. **Trabalho de Conclusão de Curso (Ciência da Computação)**. Universidade Federal da Bahia. Salvador-Bahia, 2008.

SOHN, G.; DOWMAN, I. J. Terrain surface reconstruction by the use of tetrahedron model with the MDL criterion. **International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences**, v. 34, n. 3/A, p. 336-344, 2002.

TOSHEV, A.; TASKAR, B.; DANIILIDIS, K. Object detection via boundary structure segmentation. In: **Computer Vision and Pattern Recognition (CVPR), 2010 IEEE Conference on**. IEEE, 2010. p. 950-957.

VOSSELMAN, G.; DIJKMAN, S. 3D building model reconstruction from point clouds and ground plans. **International archives of photogrammetry remote sensing and spatial information sciences**, v. 34, n. 3/W4, p. 37- 44, 2001.

WACK, R.; WIMMER, A. Digital terrain models from airborne laserscanner data-a grid based approach. **International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences**, v. 34, n. 3/B, p. 293-296, 2002.

WEHR, A.; LOHR, U. Airborne laser scanning—an introduction and overview. **ISPRS Journal of photogrammetry and remote sensing**, v. 54, n. 2-3, p. 68-82, 1999.

WEINMANN, M.; JUTZI, B.; MALLET, C. Feature relevance assessment for the semantic interpretation of 3D point cloud data. **ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 5, p. W2, 2013.

WEST, K. F.; WEBB, B.N.; LERSCH, J. R.; POTHIER, S.; TRISCARI, J. M.; & IVERSON, A.E. Context-driven automated target detection in 3D data. In: **Automatic Target Recognition XIV**. International Society for Optics and Photonics, 2004. p. 133-144.

YANG, L.; SHENG, Y.; WANG, B. 3D reconstruction of building facade with fused data of terrestrial LiDAR data and optical image. **Optik-International Journal for Light and Electron Optics**, v. 127, n. 4, p. 2165-2168, 2016.

YANO, M. S.; DAL POZ, A. P.; MENDES, T. S. G. Modelagem das faces de telhados de edifícios a partir de dados de varredura a laser. **VIII Colóquio Brasileiro de Ciências Geodésicas**, 2013.

YANO, M. S. Segmentação de telhados de edifícios em dados de varredura a LASER usando técnicas de processamento de imagem e o método RANSAC. 2015.

YANO, M. S.; DAL POZ, A. P. Segmentação de faces de telhados de edifícios em dados de varredura a laser usando o método ransac. **Revista Brasileira de Cartografia**, v. 68, n. 7, 2016.